

## 9. VDI/VDE-Fachtagung

# AUTOREG 2019

Regelungstechnik für automatisiertes Fahren und vernetzte Mobilität

Mannheim, 02. und 03. Juli 2019

Bildquelle: © ZF Friedrichshafen AG



**VDI-BERICHTE**  
Herausgeber:  
VDI Wissensforum GmbH

## **Bibliographische Information der Deutschen Nationalbibliothek**

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliographie; detaillierte bibliographische Daten sind im Internet unter [www.dnb.de](http://www.dnb.de) abrufbar.

## **Bibliographic information published by the Deutsche Nationalbibliothek (German National Library)**

The Deutsche Nationalbibliothek lists this publication in the Deutsche Nationalbibliographie (German National Bibliography); detailed bibliographic data is available via Internet at [www.dnb.de](http://www.dnb.de).

## **© VDI Verlag GmbH · Düsseldorf 2019**

Alle Rechte vorbehalten, auch das des Nachdruckes, der Wiedergabe (Photokopie, Mikrokopie), der Speicherung in Datenverarbeitungsanlagen und der Übersetzung, auszugsweise oder vollständig.

Der VDI-Bericht, der die Vorträge der Tagung enthält, erscheint als nichtredigierter Manuscriptdruck.

Die einzelnen Beiträge geben die auf persönlichen Erkenntnissen beruhenden Ansichten und Erfahrungen der jeweiligen Vortragenden bzw. Autoren wieder. Printed in Germany.

ISSN 0083-5560

ISBN 978-3-18-092349-9

# Inhalt

## ► Jahrmarkt der Innovationen

Modellbasierte Folgeregelung für nichtlineare Regelstrecken am Beispiel der Ladedruckregelung – Ein applikationsnaher Entwurf . . . . .	1
K. Wulff, J. Willkomm, J. Reger, Fachgebiet Regelungstechnik, Technische Universität Ilmenau	
Nichtlineare modellbasierte prädiktive Regelung der Fahrzeugdynamik in Bezug auf eine aktive Wankstabilisierung und eine Nickreduzierung . . . . .	3
P. M. Sieberg, S. Blume, S. Reicherts, D. Schramm, Lehrstuhl für Mechatronik, Universität Duisburg-Essen	
(Doppelpublikation: VDI Verlag Düsseldorf – Springer Nature)	
Identifikation lokal linearer Modelle am Beispiel der Ladedruckstrecke eines Ottomotors . . . . .	19
S. Kettlitz, E. Schulz, M. Schultalbers,	
IAV Automotive Engineering, Gifhorn	
Generic Sensor Modelling – A Virtual Integration Approach for the Test of ADAS. . . . .	21
A. Prinz, BMW Group, München;	
L. Brabetz, M. Ayeb, Universität Kassel	
Simulation mit Originalsteuerungssoftware im Kundenaustausch. . . . .	23
M. Mattheai, M. Fessler, ZF Friedrichshafen AG, Friedrichshafen	

## ► Anwendung von lernbasierten Methoden

Learning-Based Path Following Control for an Over-Actuated Robotic Vehicle . . . . .	25
J. Ultsch, J. Brembeck, R. de Castro, Institute of System Dynamics and Control, Department for Vehicle System Dynamics, German Aerospace Center, Oberpfaffenhofen	
A Simulation-Based Reinforcement Learning Approach for Long-Term Maneuver Planning in Highway Traffic Scenarios . . . . .	47
D. Augustin, J. Schucker, J. Tscherner, M. Hofmann, Opel Automobile GmbH, Rüsselsheim;	
U. Konigorski, Technische Universität Darmstadt	
Fahrzeugdetektion mit stationären Kameras zur automatischen Verkehrsüberwachung . . . . .	61
M. Oeljeklaus, N. Stannartz, M. Schmidt, F. Hoffmann, T. Bertram,	
Lehrstuhl für Regelungssystemtechnik, Technische Universität Dortmund	
(Doppelpublikation: VDI Verlag Düsseldorf – Springer Nature)	

## ► **Grundlagen zum automatisierten Fahren**

---

- Analyse und Unterstützung von Fahrereingriffen in dynamischen, kritischen Situationen beim hochautomatisierten Fahren . . . . .** 77  
T. Nguyen, S. Müller, Fachbereich Kraftfahrzeugtechnik, Technische Universität Berlin

- Relaxed Barrier MPC for Reference Tracking: Theoretical and experimental studies . . . . .** 97  
F. Pfitz, M. Braun, Porsche Engineering Services GmbH, Bietigheim-Bissingen;  
C. Ebenbauer, Institute for Systems Theory and Automatic Control, University of Stuttgart

## ► **Fahrstrategien**

---

- Prediction of Highway Lane Changes Based on Prototype Trajectories . . . . .** 111  
D. Augustin, M. Hofmann, Opel Automobile GmbH, Rüsselsheim;  
U. Konigorski, Technische Universität Darmstadt  
(Doppelpublikation: VDI Verlag Düsseldorf – Springer Nature)

- Bewegungssteuerung für ein Robo-Taxi mit Symmetrie in Antrieb und Lenkung . . . . .** 129  
T. Raste, P. Lauer, Continental, Frankfurt am Main

- Energy-Optimal Adaptive Cruise Control based on Model Predictive Control in the Real Driving Emissions Test Cycle . . . . .** 145  
Y. Jia, U. Schwarz, Electrification system R&D, DENSO Automotive Deutschland GmbH,  
Wegberg;  
D. Görges, Electromobility Research Group, Technische Universität Kaiserslautern

## ► **Fahrsimulation**

---

- Proof-of-Concept einer komplexen Co-Simulationsumgebung für einen Fahrsimulator zur Untersuchung von Car2X-Kommunikations-Szenarien . . . . .** 159  
S. Henning, D. S. Buse, M. Franke, A. Trächtler, S. Gausemeier, F. Dressler,  
Heinz Nixdorf Institut, Universität Paderborn

- Digitalisierung von Lichtverteilungen zur Hardware-in-the-Loop-Verifikation und Validierung von Matrixscheinwerfern . . . . .** 171  
M. Waldner, T. Bertram, Lehrstuhl für Regelungssystemtechnik, Technische Universität Dortmund

- Hardware-in-the-Loop Simulation of High-Definition Headlamp Systems . . . . .** 183  
N. Rüddenkla, S. Gausemeier, A. Trächtler, Heinz Nixdorf Institut, Universität Paderborn

## ► Fahrerassistenzsysteme

---

Full Speed Range Adaptive Cruise Control – Anforderungen und Herausforderungen in der Praxis . . . . .	195
R. Stanchev, Continental Engineering Services GmbH, Frankfurt a. M.;	
F. Becker, Continental Teves AG & Co. oHG, Frankfurt a. M.	
Vorsteuerungsentwurf für einen robusten Zwei-Freiheitsgrade Schlupfregler für Antiblockiersysteme . . . . .	209
P. Vogt, S. Schulze, E. Lenz, U. Konigorski, Technische Universität Darmstadt, Darmstadt;	
A. Klug, H. Westerfeld, Robert Bosch GmbH, Abstatt	

## ► Fahrwerksregelung

---

Intelligentes Fahrwerk – Datenquelle Cloud . . . . .	221
A. Noll, R. Schwarz, D. Reitze, Audi AG, Ingolstadt;	
K. Riedl, Lehrstuhl für Fahrzeugtechnik (FTM), Technische Universität München	
Regelung eines redundant aktuierten Steer-by-Wire-Systems – Control of redundant actuated Steer-by-Wire-Systems . . . . .	233
V. Ewald, U. Konigorski, Regelungstechnik und Mechatronik, Technische Universität Darmstadt	
(Doppelpublikation: VDI Verlag Düsseldorf – Springer Nature)	
Model Predictive Control of an Active Roll Stabilization System . . . . .	245
G. Nareyko, T. Koch, A. Trächtler, University of Paderborn	

## ► Plenarvortrag

---

Schrittweise zum sicheren automatisierten Fahren auf der Autobahn . . . . .	257
D. Hötzer, Robert Bosch GmbH, Stuttgart	

## ► Trajektorienplanung für automatisiertes Fahren

---

A Complete Concept for Combined Longitudinal and Lateral Trajectory Planning for Automated Driving on Highways. . . . .	259
J. Schucker, T. Kohlmann, Opel Automobile GmbH, Rüsselsheim; U. Konigorski, Technische Universität Darmstadt	
Decentralized Path Planning for Cooperating Autonomous Vehicles. . . . .	271
S. Rothfuß, R. Preznyakov, M. Flad, S. Hohmann, Institute of Control Systems (IRS) at the Karlsruhe Institute of Technology (KIT), Karlsruhe (Doppelpublikation: VDI Verlag Düsseldorf – Springer Nature)	
Echtzeitfähige Trajektoriengenerierung für hochautomatisierte und autonome Fahrzeuge bei Zustands- und Stellgrößenbeschränkungen. . . . .	285
Steffen Joos, Robert Bosch GmbH, Abstatt/Renningen; Roktim Bruder, Thomas Specker, Matthias Bitzer, Robert Bosch GmbH, Renningen; Knut Graichen, Lehrstuhl für Automatisierungstechnik, Friedrich-Alexander Universität Erlangen-Nürnberg, Erlangen	

## ► Fahrkomfort und automatisiertes Fahren

---

Review and experimental evaluation of models for drivability simulation with focus on tire modeling Short Version. . . . .	293
K. Figel, F. Svaricek, Bundeswehr University Munich; M. Schultalbers, IAV GmbH, Gifhorn (Doppelpublikation: VDI Verlag Düsseldorf – Springer Nature)	
Aktive Kompensation von Sitzschwingungen in Nutzfahrzeugen – Auswahl, Integration, Erprobung einer aktiven Sitzhöhenregelung . . . . .	313
M. Plinke, P. M. Marienfeld, M. Werhahn, H.-J. Karkosch, ContiTech Vibration Control GmbH, Hannover	
Objectification Methods for Ride Comfort – Comparison of Conventional Methods and Proposal of a new Method for Automated Driving Conditions . . . . .	323
E. Enders, F. Fent, M. Lienkamp, Technical University of Munich, Munich; G. Burkhard, Bayerische Motoren Werke AG, Munich; D. Schramm, University of Duisburg-Essen, Duisburg;	

## ► **Steuerung vernetzter Fahrzeuge**

---

- Kooperative Steuerung vernetzter Fahrzeuge . . . . .** 353  
A. Schwab, J. Lunze, Lehrstuhl für Automatisierungstechnik und Prozessinformatik (ATP),  
Ruhr-Universität Bochum

- Simulation von interagierenden Verkehrsteilnehmern in einer urbanen Testumgebung  
mittels einer skalierten Fahrzeugplattform . . . . .** 367  
C. Hebisch, F.-J. Heßeler, D. Abel, Institut für Regelungstechnik, RWTH Aachen

## ► **Regelung von Verbrennungsmotoren**

---

- Polytopic LPV Controller Design to Control the Boost Manifold Pressure in an Internal  
Combustion Engine . . . . .** 377  
N. Althar Udupa, E. Schulz, M. Schultalbers, IAV Automotive Engineering GmbH, Gifhorn

- Gain-Scheduling-Regelung des Ladedrucks eines Ottomotors auf Basis lokaler linearer  
strukturierter  $H^\infty$ -optimaler Regler – Systematische robuste Bedeutung einer  
konventionellen Reglerstruktur . . . . .** 389  
F. Nolteernsting, R. Röthig, T. Oehlschlägel, M. Schultalbers, U. Becker, IAV GmbH, Gifhorn

- Automated design of structured gain-scheduling oil pressure controllers by modern  
synthesis methods . . . . .** 403  
F. Hundertmark, M. Grotjahn, Hochschule Hannover

## ► **Regelung elektrischer und hybrider Antriebe**

---

**Zusammenspiel von optimierungsbasierter Lastpunktbestimmung mit regel- und optimierungsbasierteren elektrischen Fahrentscheidungen in Plug-In-Hybrid-Fahrzeugen. . . . .** 417

R. Schmid, J. Bürger, BMW Group, München

N. Bajcinca, Technische Universität Kaiserslautern, Kaiserslautern

**Simulation von Hybrid-Nutzfahrzeugen mittels akausaler Optimierung der Betriebsstrategie . . . . .** 429

M. Greule, Y. Stoermer, Daimler Buses, EvoBus GmbH, Mannheim

**Elektrifizierung des Antriebsstrangs: Einsatz und Nutzen einer analytischen Radkraftverteilung in überaktuierten Elektrofahrzeugen . . . . .** 441

J.-E. Moseberg, Schaeffler Engineering GmbH, Nürnberg

## ► **Batterie- und Energiemanagement**

---

**Optimalsteuerung des Energieflusses in einem 48V-Bordnetz schwerer Nutzfahrzeuge . . . . .** 453

M. Dellermann, O. Gehring, Daimler AG, Stuttgart;

O. Zirn, Fakultät Fahrzeugtechnik, Hochschule Esslingen

# Modellbasierte Folgeregelung für nichtlineare Regelstrecken am Beispiel der Ladedruckregelung

## Ein applikationsnaher Entwurf

Dr. Kai Wulff, Julian Willkomm, Prof. Dr.-Ing. Johann Reger,  
Fachgebiet Regelungstechnik, Technische Universität Ilmenau

### Zusammenfassung

In diesem Beitrag wird eine Entwicklungsmethodik anhand der Ladedruckregelung eines Abgasturboladers vorgestellt. Betrachtet wird ein praxisnahes Vorgehen auf Grundlage eines experimentell identifizierten Greybox-Modells der Regelstrecke. Zielsetzung ist der Entwurf einer Folgeregelung für einen Prozess mit nicht-minimalphasiger, nichtlinearer Dynamik und Parameterunsicherheiten. Der Entwurf erfolgt modellbasiert anhand von linearen lokalen Modellen, die mittels Greybox-Identifikation auf Grundlage von Messdaten ermittelt wurden [3]. Das Vorsteuerungssignal wird von einem Modellregelkreis generiert (Modellfolgeregelung), so dass keine Inversion des Modells notwendig ist. Im Modellregelkreis wird als Prozessmodell das identifizierte lokale Modellnetz verwendet und durch Zustandsrückführung die gewünschte Dynamik aufgeprägt, [2]. Stabilität des Modellregelkreis wird mittels einer gemeinsamen quadratischen Lyapunovfunktion nachgewiesen. Die damit generierte Stellgröße liefert das Vorsteuerungssignal für den nichtlinearen Prozess. Zur Kompensation von Modellfehlern und Prozessstörungen kommt eine einfache lineare Ausgangsrückführung zum Einsatz. Verglichen mit einem klassischen inversionsbasierten Vorsteuerungsverfahren erlaubt die so generierte Vorsteuerung einen stark vereinfachten Reglerentwurf mit gleichmäßiger Regelgüte über den kompletten Arbeitsbereich [1].

- [1] J. Willkomm, K. Wulff, J. Reger: Tracking-control for the boost-pressure of a turbocharger based on a local model network. IEEE Int. Conf. on Mechatronics, 2019.
- [2] J. Willkomm, K. Wulff, J. Reger: Feedforward Control for Non-Minimumphase Local Model Networks using Model Following Control. IEEE Conference on Control Technology and Applications (CCTA), Copenhagen, 2018.
- [3] C. Weise, K. Wulff, M. Höper, R. Hurtado: Continuous-time Local Model Network for the Boost-pressure Dynamics of a Turbocharger. In: Selected papers of the IFIP TC7 Conference on System Modelling and Optimization 2013, Ch. Pötsche, C. Heuberger, B. Kaltenbacher, F. Rendl (Eds), pp. 348--358, Springer, 2014



# Nichtlineare modellbasierte prädiktive Regelung der Fahrzeugdynamik in Bezug auf eine aktive Wankstabilisierung und eine Nickreduzierung

## Non-Linear Model-Based Predictive Control of Vehicle Dynamics in Terms of Active Roll Stabilization and Pitch Reduction

**Philipp Maximilian Sieberg**, M.Sc., Dipl. Math. **Sebastian Blume**,  
**Sebastian Reicherts**, M.Sc., Prof. Dr.-Ing. Dr. h.c. **Dieter Schramm**,  
Lehrstuhl für Mechatronik, Universität Duisburg-Essen

### Kurzfassung

Im vorliegenden Beitrag wird ein nichtlinearer modellbasierter Regelungsansatz vorgestellt, der die Fahrzeugdynamik, im Speziellen das Wank- und Nickverhalten eines Personenkarosseries, gezielt beeinflusst. Das Ziel einer solchen Fahrdynamikregelung ist es, sowohl die Sicherheit in kritischen Grenzbereichen der Fahrdynamik zu erhöhen, als auch den Komfort während der Fahrt generell zu steigern. Das Wanken ist als Rotation um die fahrzeugfeste Längsachse definiert. Eine Drehung um die laterale fahrzeugfeste Achse wird durch das Nicken beschrieben. Aufbauend auf einem nichtlinearen prädiktiven Regelalgorithmen zur aktiven Wankstabilisierung (vgl. Sieberg et al. [1]) wird bei dem hier vorgestellten Regelungsansatz das Nickverhalten zusätzlich verringert. Über den modellierten Fahrzeugaufbau, ausgestattet mit aktiven Stabilisatoren sowie semiaktiven Stoßdämpfern, lassen sich insbesondere durch letztere Aufbaubewegungen und dadurch ebenfalls Nickbewegungen verringern. Durch die Berücksichtigung des Nickverhaltens im modellbasierten prädiktiven Regler wird somit der Fahrkomfort weiter gesteigert.

## Abstract

This article presents a non-linear model-based control approach that specifically influences the vehicle dynamics, in particular the roll and pitch behavior of a passenger car. The aim of such a driving dynamics control is to increase safety in critical areas of vehicle dynamics, and generally to increase the comfort while driving. The roll behavior is defined as a rotation about the vehicle-fixed longitudinal axis. A rotation about the lateral vehicle-fixed axis is described by the pitch behavior. Based on a non-linear predictive control algorithm for active roll stabilization (see Sieberg et al. [1]), the pitch behavior is additionally reduced in the control approach presented here. Through the modeled vehicle, equipped with active stabilizers and semi-active shock absorbers, chassis movements and thereby also pitching movements can be reduced especially using the shock absorbers. By considering the pitching behavior in the model-based predictive controller, driving comfort is thus further enhanced.

## 1 Einleitung

Durch die stetig voranschreitende Entwicklung im Bereich der Fahrzeugindustrie und die sich dadurch verschärfende Konkurrenzsituation auf dem Weltmarkt werden immer höhere Anforderungen an die Produkte, den Fahrzeugen, gestellt. Neben dem Preis-Leistungsverhältnis sind vor allem der Fahrkomfort und die Sicherheit der Fahrzeuge die wichtigsten Anschaffungskriterien für Käufer (vgl. [2]). Essentielle Bestandteile der heutigen Fahrzeuge sind dabei Fahrdynamikregelsysteme. Durch die gezielte Beeinflussung von fahrdynamischen Größen können sowohl Sicherheit, als auch Komfort erhöht werden. Mögliche Regelungsansätze, die hierbei zum Einsatz kommen können, werden unter der Klasse der modellbasierten prädiktiven Regelungsalgorithmen zusammengefasst (vgl. [3], [4]). Aufbauend auf Modellwissen in Form von mathematischen Beschreibungen der Dynamik, kann das Verhalten des zu regelnden Systems prädiziert werden. Durch die Berücksichtigung dieser Vorhersagen kann die Regelungsaufgabe optimal durchgeführt werden. Im vorliegenden Beitrag wird der von Sieberg et al. [1] vorgestellte nichtlineare modellbasierte prädiktive Regelungsalgorithmus zur aktiven Wankstabilisierung in Bezug auf die Berücksichtigung des Nickverhaltens erweitert. Während das Wankverhalten vollständig geregelt wird, kann aufgrund des vorhandenen Fahrzeugaufbaus das Nickverhalten zusätzlich reduziert werden. Durch die Betrachtung zweier fahrdynamischer Größen, dem Wank- sowie dem Nickwinkel, kann die Regelung vorhandenes Synergiepotential nutzen, wodurch sich letztendlich der Fahrkomfort erhöht. Der Entwurf, die Implementierung sowie die Validierung des Regelungsalgorithmus werden mit Hilfe einer Simulation durchgeführt. In der Simulationsumgebung wird eine Co-Simulation aus MATLAB/SIMULINK und IPG CarMaker verwendet. Das Fahrzeugverhalten, Wechselwirkungen mit der Umgebung sowie das Fahrermodell werden dabei in IPG CarMaker simuliert. Der Regelungsalgorithmus, die Erstellung von Sollgrößen, sowie die Abbildung der Aktuatoren werden in MATLAB/SIMULINK durchgeführt.

Im nachfolgenden Abschnitt werden zu Beginn fundamentale Zusammenhänge der zugrundeliegenden Fahrzeugdynamik vorgestellt. Der Fokus liegt dabei auf der Beschreibung der Wank- und Nickdynamik. Weiterhin wird der Stand der Technik im Zusammenhang mit der Fahrdynamikregelung aufgezeigt. Anschließend wird die verwendete Simulationsumgebung schematisch beschrieben. Im dritten Abschnitt wird der entwickelte Regelungsalgorithmus detailliert erläutert. Es folgt die Validierung des modellbasierten prädiktiven Reglers anhand eines Fahrmanövers, welches Übergangsverhalten zwischen Geradeausfahrt und Kurvenfahrt abbildet. Abschließend wird der Beitrag zusammengefasst. Zudem wird ein Ausblick auf weiterführende Forschungsaufgaben vorgestellt.

## 2 Grundlagen

Im folgenden Abschnitt werden zunächst die Grundlagen der Fahrzeugdynamik vorgestellt. Dabei werden gezielt sowohl das Wank-, als auch das Nickverhalten von Fahrzeugen in Form ihrer Bewegungsgleichungen betrachtet. Zudem wird ein Überblick über den Stand der Technik für den Bereich der Fahrdynamikregelung gegeben. Anschließend werden die verwendete Simulationsumgebung und das eingesetzte Fahrzeug sowie die verwendeten Aktuatoren eingeführt.

### 2.1 Fahrzeugdynamik

Für die Untersuchungen des Fahrzeugverhaltens sowie eine anschließend aufbauende Regelung spezifischer dynamischer Größen wird zunächst generell auf die Dynamik von Fahrzeugen eingegangen. Wie Schramm et al. [5] in ihrem Beitrag zu den technischen Grundlagen aktueller und zukünftiger Kraftfahrzeuge aufführen, besitzt der Fahrzeugaufbau als Starrkörper sechs Freiheitsgrade. Diese setzen sich nach DIN ISO 8855:2011 [6] aus translatorischen und rotatorischen Freiheitsgraden zusammen. Die translatorische Dynamik des Fahrzeugaufbaus wird mit Hilfe des „Zuckens“ in Fahrzeulgängsrichtung  $x_v$ , des „Schiebens“ in Fahrzeugquerrichtung  $y_v$  und des „Hebens“ in Vertikalrichtung des Fahrzeugs  $z_v$  beschrieben. Die Rotation des Fahrzeugaufbaus in Bezug auf ein Inertialsystem ist mit Hilfe der KARDAN-Winkel in der Drehreihenfolge  $x \rightarrow y \rightarrow z$  definiert. Dabei bildet das „Wanken“ die Rotation um die Longitudinalachse, das „Nicken“ die Rotation um die laterale Fahrzeugachse und das „Gieren“ die Drehung um die Vertikalachse ab.

Nachfolgend werden die Freiheitsgrade des Wankens und des Nickens aufgrund ihrer Relevanz für die in diesem Beitrag vorgestellte Regelung detaillierter betrachtet. Dazu ist in Abbildung 1 ein Freischnitt des Fahrzeugaufbaus vereinfacht illustriert. Zunächst wird die Wankdynamik mit Hilfe ihrer Bewegungsgleichung für eine horizontale Fahrbahn erläutert. Ein Drallsatz in der  $y$ - $z$ -Ebene um den Wankpol  $W$  liefert:

$$\begin{aligned} & \left( (h_s - h_w) m_A a_y - 2(s_{D,v}^2 d_{D,v} + s_{D,h}^2 d_{D,h}) \dot{\phi} \right) \cos \varphi + \left( (h_s - h_w) m_A g - 2(s_{F,v}^2 c_{F,v} + s_{F,h}^2 c_{F,h}) \right) \sin \varphi \dots \\ & - 2 \frac{c_{St,v} s_{St,v}}{b_{St,v}} \sin^{-1} \left( \frac{l_{St,v}}{2b_{St,v}} \sin \varphi \right) - 2 \frac{c_{St,h} s_{St,h}}{b_{St,h}} \sin^{-1} \left( \frac{l_{St,h}}{2b_{St,h}} \sin \varphi \right) = J_{xx} \dot{\phi} \end{aligned} \quad (1)$$

Dabei ist der Verdrehwinkel  $\varphi$  als Wankwinkel definiert. Weiterhin beschreiben  $\dot{\varphi}$  die Änderung des Wankwinkels über die Zeit und somit die Wankrate sowie  $\ddot{\varphi}$  die Wankbeschleunigung. Das Trägheitsmoment um die Rotationsachse wird durch  $J_{xx}$  berücksichtigt. Ferner bildet die Differenz  $(h_S - h_W)$  den Höhenunterschied zwischen Fahrzeugschwerpunkt S und Wankpol W im nicht ausgelenkten Zustand ab. Zum einen wird das Wankverhalten durch die Beschleunigung aus Querrichtung  $a_y$  und die Erdbeschleunigung  $g$  beeinflusst. Diese bilden in Zusammenhang mit der Fahrzeugaufbaumasse  $m_A$  äußere Eingangsgrößen ab. Weitere Eingangsgrößen resultieren aus den Kräften der Fahrwerkselemente. Betrachtet werden Federn  $F_{F,i}$ , Stoßdämpfer  $F_{D,i}$  und Stabilisatoren  $F_{St,i}$ :

$$|F_{F,i}| = c_{F,i} s_{F,i} \sin \varphi \quad (2)$$

$$|F_{D,i}| = d_{D,i} s_{D,i} \dot{\varphi} \cos \varphi \quad (3)$$

$$|F_{St,i}| = \frac{c_{St,i}}{b_{St,i}} \sin^{-1} \left( \frac{l_{St,i}}{2b_{St,i}} \sin \varphi \right) \quad (4)$$

Der Index  $i \in \{v, h\}$  kennzeichnet, ob die Vorderachse oder die Hinterachse betrachtet wird. Weiterhin entsprechen die aus dem Fahrwerk resultierenden Kräfte der linken Fahrzeughälfte, den negierten Kräften der rechten Fahrzeughälfte. Dabei repräsentieren  $c_{F,i}$  die Federsteifigkeiten,  $d_{D,i}$  die Dämpfungsmaße und  $c_{St,i}$  die Stabilisatorsteifigkeiten. Weiterhin bilden  $s_{F,i}$  und  $s_{D,i}$  die Abstände der Kraftelemente zur Mittelebene des Fahrzeugaufbaus ab. Dieser wird vereinfacht als symmetrisch angenommen. Die Stabilisatoren werden weiterhin über die geometrischen Maße der Stabilisatorhebel  $b_{St,i}$  und der Stabilisatorlängen  $l_{St,i}$  beschrieben. [7]

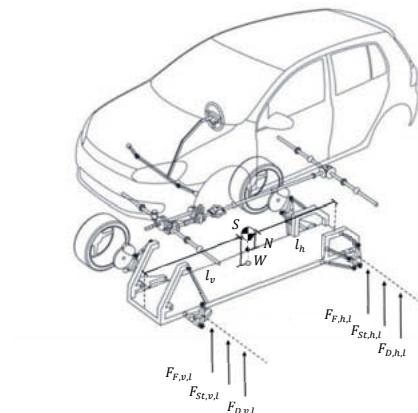


Abbildung 1 Dynamik des freigeschnittenen Fahrzeugaufbaus (in Anlehnung an [7])

Neben der Wankdynamik beeinflussen vor allem Nickbewegungen den Fahrkomfort (vgl. [8]). Die Nickdynamik auf horizontaler Fahrbahn lässt sich über einen Drallsatz in der  $x$ - $z$ -Ebene um den Nickpol N mit

$$\begin{aligned} & \left( (h_S - h_W) m_a a_x - 2(l_{D,v}^2 d_{D,v} + l_{D,h}^2 d_{D,h}) \dot{\theta} \right) \cos \theta + \left( (h_S - h_W) m_a g - 2(l_{F,v}^2 c_{F,v} + l_{F,h}^2 c_{F,h}) \right) \sin \theta \\ & = J_{yy} \ddot{\theta} \end{aligned} \quad (5)$$

beschreiben. Das Trägheitsmoment der Rotation ist durch  $J_{yy}$  definiert. Die Parameter  $l_{F,i}$  und  $l_{D,i}$  stellen die Abstände zwischen den Kraftelementen und der  $y$ - $z$ -Schwerpunktebene dar. Die Rotation um die laterale Fahrzeugachse wird durch den Nickwinkel  $\theta$ , die Nickrate  $\dot{\theta}$  und die Nickbeschleunigung  $\ddot{\theta}$  vollständig beschrieben. Vergleichbar zu dem Vorgang des Wankens wird die Nickdynamik neben der Kraft aus der Erdbeschleunigung durch eine Kraft resultierend aus der Längsbeschleunigung des Fahrzeugaufbaus  $a_x$  beeinflusst. Zusätzlich wirken sich sowohl Federn, als auch Stoßdämpfer auf die Nickbewegung aus. Um die Fahrzeugdynamik in Bezug auf das Wank- sowie das Nickverhalten beeinflussen zu können, werden Fahrwerkselemente teilweise oder gänzlich aktiv gestaltet. Darunter werden aktive Federungen, semiaktive Stoßdämpfer und aktive Stabilisatoren zusammengefasst. Die Kräfte, die aus den Fahrwerkselementen resultieren, sind somit in bestimmten, definierten Bereichen variabel gestaltbar.

Zum Beispiel können bei aktiven Stabilisatoren gezielt Konterwankmomente über einen mittig platzierten Aktuator gestellt werden (vgl. [7]). Weiterhin besteht beispielhaft die Möglichkeit, das Dämpfungsmaß der Stoßdämpfer variabel einzustellen. Bei der technischen Umsetzung dieser semiaktiven Stoßdämpfer werden entweder zusätzliche Proportionalventile oder magneto- bzw. elektrorheologische Flüssigkeiten im Dämpfer selbst verwendet. Während sich der Fluss zwischen den Kammern und somit die Dämpfung bei einem Zweirohrdämpfer über das zusätzlich eingebrachte Proportionalventil regulieren lässt, wird bei der Verwendung der elektro- bzw. magnetorheologischen Flüssigkeit die Schubspannung und dadurch das Dämpfungsmaß angepasst (vgl. [9]). Sowohl aktive Stabilisatoren als auch semiaktive Stoßdämpfer befinden sich beispielhaft bei Fahrzeugen der Dr. Ing. h. c. F. Porsche AG [10] im Einsatz.

## 2.2 Fahrodynamikregelung

Die Regelung der Fahrzeugdynamik, insbesondere mehrerer Fahrodynamikgrößen, kann grundsätzlich durch zwei unterschiedliche Ansätze erfolgen. Einerseits besteht die Möglichkeit des Einsatzes von koexistierenden vereinzelten Fahrodynamikreglern. Die Schwierigkeit dieser Lösung, besteht in der Abstimmung der einzelnen Regler. Weiterhin ergeben sich aus der stetig ansteigenden Komplexität der Fahrzeuge, welche letztendlich mit der Anzahl der Fahrodynamikregler korreliert, konträre Beeinflussungen. Dieses führt letztendlich zu negativen Regelergebnissen bezogen auf die Gesamtdynamik des Fahrzeugs [11]. Die zweite grundlegende Möglichkeit zur Regelung der Fahrodynamik, stellt die Methode der integrativen Regelung dar. Dieser Ansatz bildet zwar einen höheren Entwicklungsaufwand ab, vermeidet jedoch durch die gesamtheitliche Arbeitsweise die Nachteile des Ansatzes der Koexistenz. Durch diesen Ansatz werden nicht nur negative Beeinflussungen vermieden, vielmehr können vorhandene Synergien ausgenutzt werden [12]. Eine integrative Fahr-

namikregelung kann weiterhin hinsichtlich ihrer Architektur klassifiziert werden. Hierbei werden zentrale und dezentrale Strukturen unterschieden. Bei einer dezentralen Struktur sind die einzelnen Regler teilweise weiterhin unabhängig. Im Gegensatz zur reinen Koexistenz, liegt zusätzlich ein Austausch zwischen den Subsystemen vor. Bei Bedarf kann somit ein gemeinsames sowie gesamtheitliches Ziel durch eine Zusammenarbeit erreicht werden. Der zentralen Struktur liegt ferner ein einzelner Regler zu Grunde, der alle geforderten Regelziele gesamtheitlich verfolgt [13]. Den Vorteilen wie etwa der Ausnutzung vorhandener Synergien steht hier vor allem der Nachteil der benötigten Rechenkapazität gegenüber [14]. Ein Kompromiss der vorgestellten Methoden stellen teilintegrative Regelungsstrukturen dar. Hierbei werden gezielt definierte Regelziele zusammengefasst, während andere Regelungsaufgaben entkoppelt durchgeführt werden. Durch die Kombination der jeweiligen Vorteile wird ein Übergang von getrennten Reglern hin zum zentralen Regelungssystem gefördert. Während bei koexistenten Regelungsaufgaben der Fahrdynamik häufig PID-Regler eingesetzt werden, eignen sich für integrative Regelungsaufgaben besonders Regler, welche auf Systemwissen basieren [15]. Zu diesen zählen unter anderem Zustandsregler und ferner modellbasierte prädiktive Regler. In [16] wird ein modellbasierter prädiktiver Regler beispielhaft zur gesamtheitlichen Beeinflussung des Wankwinkels und der Gierrate verwendet.

### 2.3 Simulationsumgebung

Für die Aufgabe des Reglerentwurfs und die anschließende Validierung ist es einerseits notwendig das Fahrzeugverhalten, insbesondere die Dynamik sowie die Interaktion zwischen Fahrzeug, Fahrer und Umgebung, sehr detailliert abbilden zu können. Andererseits muss eine Entwicklungsumgebung verwendet werden, in der Berechnungen, Optimierungen sowie Aktuatormodelle ausgeführt werden können. Aufgrund dieser notwendigen Anforderungen wird zur Entwicklung des in diesem Beitrag vorgestellten modellbasierten prädiktiven Regelungsalgorithmus eine Co-Simulation, bestehend aus IPG CarMaker und MATLAB/SIMULINK, gewählt. Der schematische Aufbau der Simulationsumgebung wird in Abbildung 2 dargestellt. Die detaillierte Abbildung der Fahrzeugdynamik, inklusive der Interaktion zwischen einem virtuellen Fahrer und der Umgebung, erfolgt gesamtheitlich durch IPG CarMaker. Dabei wird ein „Sports Utility Vehicle“, kurz SUV, als Testfahrzeug verwendet. Durch einen erhöhten Schwerpunkt besitzt dieses Fahrzeug eine starke Ausprägung Wank- und Nickbewegungen durchzuführen.

Das Fahrzeug wird zudem in Anlehnung an Sieberg et al. [1] seitens IPG CarMaker lediglich mit passiven Federn ausgestattet. In MATLAB /SIMULINK wird die gesamte Regelungsaufgabe durchgeführt. Abhängig von den aktuellen Fahrzeugzuständen, die zum Teil aus IPG CarMaker übertragen oder zusätzlich durch geeignete Schätzermodelle berechnet werden, wird zunächst das Sollwankverhalten bestimmt. Um die Interaktion zwischen Fahrer und Fahrzeug aufrechtzuerhalten wird ein dynamisches Sollwankverhalten vorgegeben. Dieses reduziert den Wankwinkel in Bezug auf ein passives Fahrzeug.

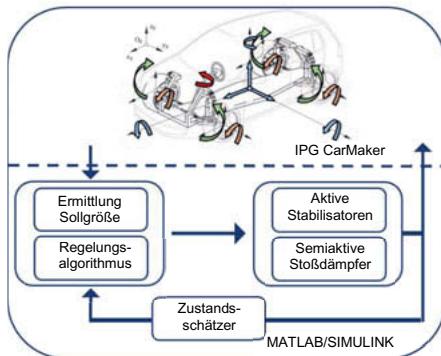


Abbildung 2 Schematischer Aufbau der Simulationsumgebung

Durch den definierten Aufbau mit aktiven Stabilisatoren, semiaktiven Stoßdämpfern und passiven Federn, lässt sich das Nickverhalten nicht direkt regeln. Jedoch besteht das Potential, die Nickbewegung mit Hilfe der semiaktiven Dämpfer zu verringern. Dadurch beträgt der Sollnickwinkel konstant  $\theta_{ref} = 0$ . Er ist somit unabhängig von den Fahrzuständen. Anschließend wird, abhängig von den aktuellen Zuständen des Fahrzeugs, die nichtlineare modellbasierte prädiktive Regelung zur Wankstabilisierung und Nickreduzierung durchgeführt. Die Reglerausgaben stellen wiederum Sollgrößen für die aktiven Stabilisatoren und die semiaktiven Stoßdämpfer dar. Über ein definiertes Übertragungsverhalten der Aktuatoren wird ebenfalls eine realistische Abbildung selbiger sichergestellt. Nachfolgend werden die durch die Fahrwerkselemente abgebildeten Kräfte an das Testfahrzeug in IPG CarMaker übertragen. Durch diese Kopplung wird eine Closed-Loop-Simulation durchgeführt, was vor allem für die Implementierung und Validierung des Regelungsalgorithmus unabdingbar ist.

### 3 Aktive Wankstabilisierung inklusive Nickreduzierung

Der entwickelte Regelungsalgorithmus beruht auf der Ausarbeitung der nichtlinearen modellbasierten prädiktiven Wankstabilisierung von Sieberg et al. [1]. Aufbauend auf diesem Ansatz ist die Regelungsaufgabe um die Reduzierung der Nickbewegung erweitert worden. Analog zu der genannten Umsetzung wird die für die regelungsinterne Prädiktion des Systemverhaltens das semi-implizite Eulerverfahren verwendet (vgl. [17]). Die Differentialgleichungen für das Wank- und Nickverhalten werden durch

$$\dot{\varphi}(k+1) = \dot{\varphi}(k) + \ddot{\varphi}(k) \cdot dt, \quad (6)$$

$$\dot{\theta}(k+1) = \dot{\theta}(k) + \ddot{\theta}(k) \cdot dt, \quad (7)$$

$$\varphi(k+1) = \varphi(k) + \dot{\varphi}(k+1) \cdot dt, \quad (8)$$

$$\theta(k+1) = \theta(k) + \dot{\theta}(k+1) \cdot dt \quad (9)$$

gelöst. Die zugrunde liegende Schrittweite beträgt  $dt = 10$  ms. Abhängig von den Winkelgeschwindigkeiten  $\dot{\varphi}$  und  $\dot{\theta}$  sowie den Winkelbeschleunigungen  $\ddot{\varphi}$  und  $\ddot{\theta}$  wird das Wank- und das Nickverhalten diskret in Form des Wank- und Nickwinkels vorhergesagt (vgl. Gl. (6) – Gl. (9)). Die Wankbeschleunigung  $\ddot{\varphi}$  zum Zeitpunkt  $k$  lässt sich angelehnt an Gl. (1) unter Berücksichtigung der aktuierten Fahrwerkselemente durch

$$\ddot{\varphi}(k) = \frac{1}{J_{xx}} [(h_s - h_w)m_A a_y \cos \varphi(k) + (h_s - h_w)m_A g \sin \varphi(k) - 2(s_{F,v}^2 c_{F,v} + s_{F,h}^2 c_{F,h}) \sin \varphi(k) \dots \\ - u_1(k) - ((u_2(k) + u_3(k))s_{D,v}^2 + (u_4(k) + u_5(k))s_{D,h}^2) \dot{\varphi}(k) \cos \varphi(k)] \quad (10)$$

bestimmen. Die Eingangsgröße  $u_1$  stellt das Konterwankmoment dar, welches durch die beiden aktiven Stabilisatoren gesamtheitlich aufgebracht wird. Über die Geometrie der Stabilisatoren wird das Konterwankmoment in die Stabilisatormomente umgerechnet. Dabei werden 50 % des Konterwankmoments auf die Vorderachse und 50 % auf die Hinterachse aufgeteilt. Die Eingangsgrößen  $u_2$ ,  $u_3$ ,  $u_4$  und  $u_5$  bilden die Dämpfungsmaße der semiaktiven Stoßdämpfer ab. Während  $u_2$  und  $u_3$  die Stoßdämpfer an den Radaufhängungen vorne links sowie vorne rechts abbilden, stellen  $u_4$  und  $u_5$  das Dämpfungmaß der Aufhängung hinten links beziehungsweise hinten rechts dar. Analog zur Bestimmung der Wankbeschleunigung  $\ddot{\varphi}$  wird die Nickbeschleunigung über den Drallsatz unter Berücksichtigung der verwendeten Aktuatorik über

$$\ddot{\theta}(k) = \frac{1}{J_{yy}} [(h_s - h_N)m_A a_x \cos \theta(k) + (h_s - h_N)m_A g \sin \theta(k) - 2(l_{F,v}^2 c_{F,v} + l_{F,h}^2 c_{F,h}) \sin \theta(k) \dots \\ - ((u_2(k) + u_3(k))l_{D,v}^2 + (u_4(k) + u_5(k))l_{D,h}^2) \dot{\theta}(k) \cos \theta(k)] \quad (11)$$

berechnet. Um stetige Verläufe der Stellgrößen über die präzidierten Trajektorien der Regelgrößen zu erhalten, werden die Stellgrößen über die Polynome

$$u_1 = a_{11} + a_{12}t + a_{13}t^2 + a_{14}t^3, \quad (12)$$

$$u_2 = a_{21} + a_{22}t + a_{23}t^2, \quad (13)$$

$$u_3 = a_{31} + a_{32}t + a_{33}t^2, \quad (14)$$

$$u_4 = a_{41} + a_{42}t + a_{43}t^2, \quad (15)$$

$$u_5 = a_{51} + a_{52}t + a_{53}t^2 \quad (16)$$

beschrieben. Durch diese Art der Beschreibung werden Sprünge in den Stellgrößentrajektorien vermieden. Unter Berücksichtigung der gewünschten Stellgrößenverläufe mit möglichst wenig Überschwingen und des vorhandenen Systemaufbaus wird das Konterwankmoment über ein kubisches Polynom sowie die einzelnen Dämpfungsmaße über quadratische Polynome ausgedrückt. Die Stellgrößentrajektorien werden hierbei über den Prädiktionshorizont  $n_p = 15$  gebildet. Dabei wird eine Schrittweite von 0,01 Sekunden verwendet. Um weiterhin die physikalischen Grenzen der Aktuatoren zu berücksichtigen, werden zusätzlich Stellgrößenbeschränkungen in dem nichtlinearen modellbasierten prädiktiven Regelungsalgorithmus einbezogen.

$$M_{ko,min} \leq u_1 \leq M_{ko,max} \quad (17)$$

$$d_{min} \leq u_i \leq d_{max}, \quad i \in \{2,3,4,5\} \quad (18)$$

In der in diesem Beitrag vorgestellten Regelung muss somit unter Berücksichtigung der Nebenbedingungen folgendes Optimierungsproblem gelöst werden:

$$\begin{aligned} \min_{\boldsymbol{a}} f(\boldsymbol{u}(\boldsymbol{a}), \boldsymbol{x}) = & \lambda_W \sum_{i=1}^{n_p} (\varphi_{soll}(k+i) - \varphi(k+i))^2 + \lambda_N \sum_{i=1}^{n_p} (\theta_{soll}(k+i) - \theta(k+i))^2 \dots \\ & + \lambda_{u_1} \sum_{i=1}^{n_p} u_1(k+i)^2 + \lambda_{u_2} \sum_{i=1}^{n_p} u_2(k+i)^2 + \lambda_{u_3} \sum_{i=1}^{n_p} u_3(k+i)^2 \dots \\ & + \lambda_{u_4} \sum_{i=1}^{n_p} u_4(k+i)^2 + \lambda_{u_5} \sum_{i=1}^{n_p} u_5(k+i)^2 \end{aligned} \quad (19)$$

mit

$$\boldsymbol{u} = (u_1, u_2, u_3, u_4, u_5)^T, \quad (20)$$

$$\boldsymbol{a} = (a_{11}, \dots, a_{53})^T \quad (21)$$

und

$$\boldsymbol{x} = (\varphi_{soll}, \varphi, \theta_{soll}, \theta)^T. \quad (22)$$

Neben den Regelabweichungen zwischen den Sollwinkeln  $\varphi_{soll}$ ,  $\theta_{soll}$  und den prädizierten Winkeln  $\varphi$ ,  $\theta$  werden ebenfalls die Stellgrößen  $u_1, u_2, u_3, u_4, u_5$  in der Kostenfunktion berücksichtigt. Durch die Gewichtung der einzelnen Größen über  $\lambda_W$ ,  $\lambda_N$ ,  $\lambda_{u_1}$ ,  $\lambda_{u_2}$ ,  $\lambda_{u_3}$ ,  $\lambda_{u_4}$  und  $\lambda_{u_5}$  kann der Regelungsalgorithmus hinsichtlich des Energiebedarfs der Aktuatoren und somit auch des Gesamtfahrzeugs sowie der Regelgüte angepasst werden. Die Optimierung erfolgt durch das Interior-Point Verfahren unter Verwendung der Optimization Toolbox von MATLAB. Dieses Verfahren verwendet für die Minimierung zunächst einen direkten Newton-Schritt. Falls dieser Ansatz nicht erfolgreich ist, wird die Optimierung iterativ mit Hilfe des konjugierten Gradienten unter Berücksichtigung einer Vertrauensregion durchgeführt.

#### 4 Validierung

Der entwickelte modellbasierte prädiktive Regelungsalgorithmus zur aktiven Wankstabilisierung inklusive einer Nickreduzierung wird gegenüber einem Testfahrzeug mit vollständig passivem Fahrwerk validiert. Dazu wird das Fahrmanöver der Sinuslenkeingabe verwendet. In Anlehnung an ISO 13674-1:2010 [18] und ISO 7401:2011 [19] wird ein Sinuslenken konstanter Amplitude und Frequenz vorgegeben. Die Lenkvorgabe wird mit einem Lenkradwinkel von  $\alpha_{LR} = 50^\circ$  und der Frequenz  $f = 1 \text{ Hz}$  durchgeführt. Dieses entspricht einem Lenkwinkel von  $\alpha = 2,65^\circ$ . Zu Beginn des Fahrmanövers

befindet sich das Fahrzeug in Ruhe und beschleunigt anschließend bei Geradeausfahrt bis zur Zielgeschwindigkeit  $v = 60 \frac{km}{h}$ . Nachfolgend wird die Geschwindigkeit während der anschließenden Sinuslenkeingabe konstant gehalten. In Anlehnung an die Beiträge von Rönitz et al. [20] und Zomotor et al. [21] ist das Fahrmanöver des Sinuslenkens in den Bereich des Übergangsverhalten zwischen Geradeaus- und Kurvenfahrt einzuordnen.

#### 4.1 Wankverhalten

Zunächst wird das Wankverhalten für das Fahrmanöver des Sinuslenkens untersucht und der entwickelte prädiktive Regelungsalgorithmus anhand dessen validiert. Das Wankverhalten wird dabei über den Verlauf des Wankwinkels während des Fahrmanövers untersucht. Der Wankwinkel entspricht hierbei einer der beiden Zielgrößen der Regelungsaufgabe. Das Wankverhalten wird in Abbildung 3 dargestellt. Dabei wird gezielt der Bereich der sinusförmigen Lenkeingabe betrachtet.

Der Wankwinkelverlauf des Testfahrzeugs mit passiven Fahrwerkselementen wird durch eine dunkelgraue gepunktete Linie illustriert. Das Sollwankverhalten in Form der Führungsgröße des Regelungsalgorithmus wird durch eine durchgezogene schwarze Linie abgebildet. Das Wankverhalten, welches durch die Verwendung der nichtlinearen modellbasierten prädiktiven Regelung entsteht, wird durch eine hellgraue gestrichelte Linie dargestellt.

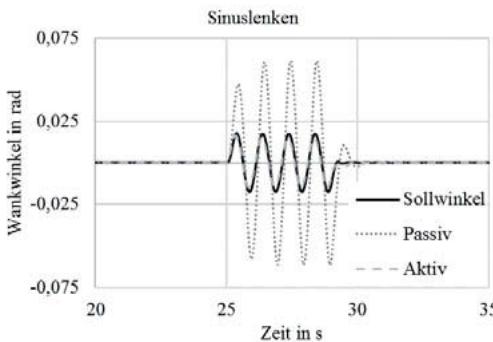


Abbildung 3 Wankwinkelverlauf bei einer sinusförmigen Lenkvorgabe

Bei der Bestimmung der Führungsgröße während der Regelungsaufgabe wird ein Sollwinkelwinkel vorgegeben, der 25 Prozent des Winkelwinkels eines potentiellen Testfahrzeugs mit passivem Fahrwerk entspricht. Dazu wird in diesem Teil der Regelungsaufgabe zusätzlich ein Wankmodell mit passiven Fahrwerkselementen (vgl. Gl. (1)) simuliert und mit einer nachfolgenden Skalierung verknüpft. Um die Regelgüte über den gesamten sinusförmigen Lenkvorgang bewerten zu können, wird die quadratische Regelabweichung in diskreter Ausführung verwendet. Dabei wird die Summe der quadrierten Regelabweichungen über das gesamte Fahrmanöver gebildet.

$$R_{qu} = \sum_{t=0}^{t_{end}} [\varphi_{ref}(t) - \varphi(t)]^2 \quad (23)$$

Für das vorgestellte Fahrmanöver liegt eine quadratische Regelabweichung von  $R_{qu} = 0,0018 \text{ rad}^2$  vor. Dieses entspricht einer mittleren quadratischen Regelabweichung von  $\Delta\varphi_{qu,m} = 6,12 \cdot 10^{-7} \text{ rad}^2$  pro Zeitschritt.

In Abbildung 4 werden beispielhaft die Stellgrößenverläufe des Konterwankmoments  $u_1$  sowie der Dämpfungsmaße der Radaufhängung vorne links VL sowie hinten rechts HR für den Zeitraum der Lenkvorgabe illustriert.

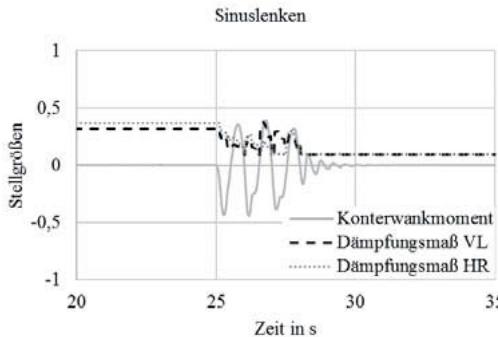


Abbildung 4 Skalierte Stellgrößenverläufe bei einer sinusförmigen Lenkvorgabe

Die Betrachtung erfolgt hierbei für skalierte Stellgrößen. Einerseits wird mit Hilfe dieser Darstellung deutlich, dass hohe Stellgrößen während der modellbasierten prädiktiven Regelung bestraft werden. Beispielhaft wird nahezu kein Konterwankmoment während der Geradeausfahrten vorgegeben. Weiterhin ist zu erkennen, dass stetige Stellgrößenverläufe vorliegen. Dieses resultiert aus der Betrachtung der Stellgrößen in Form der beschriebenen Polynome. Zusätzlich zu diesen beiden Erkenntnissen, wird die in der Regelung berücksichtigte gesamtheitliche Betrachtung von Wanken und Nicken ersichtlich. Die Dämpfungsmaße vor der Lenkvorgabe und somit während der Beschleunigungsfahrt unterscheiden sich aufgrund ihres jeweiligen Einflusses auf die Nickbewegung. Dieses Verhalten ist auch während des Sinuslenkens erkennbar, bei dem maßgeblich die Wankbewegung Einfluss besitzt. Bei der anschließenden Geradeausfahrt mit konstanter Geschwindigkeit, bei der weder Wank- noch Nickbewegungen vorliegen, werden beide Dämpfungsmaße sowie das Konterwankmoment minimal.

## 4.2 Nickverhalten

Die Validierung des Nickverhaltens wird für das vorgestellte Fahrmanöver zweigeteilt. Zunächst wird der Bereich der Beschleunigung zu Beginn des Manövers betrachtet. Während der Beschleunigungsphase besitzen besonders die Vorgänge des Gangwechsels großen Einfluss auf das Nickverhalten. Dazu wird der Nickwinkel über den Zeitraum der Beschleunigungsphase aufgetragen. Dieses wird in Abbildung 5 dargestellt. Das Testfahrzeug mit passivem Fahrwerk wird analog zu der Darstellung in Abschnitt 4.1 durch eine dunkelgraue gepunktete Linie visualisiert, während das Testfahrzeug mit aktivem Fahrwerk unter Verwendung der vorgestellten Regelung durch eine hellgraue gestrichelte Linie repräsentiert wird.

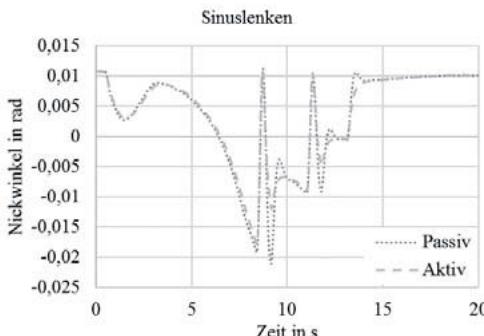


Abbildung 5 Nickwinkelverlauf während der Beschleunigungsphase

Beispielhaft wird der Vorgang des ersten Gangwechsels betrachtet. Dieser findet im Zeitraum von 8,38 Sekunden bis 10,03 Sekunden statt. Der Einfluss der spezifischen Stoßdämpfereinstellung wird vor allem während der Vorgänge des Einkuppelns und der Gangeinlage deutlich.

Durch die Berücksichtigung des Nickverhaltens in der nichtlinearen modellbasierten prädiktiven Regelung wird eine Verringerung des Nickverhaltens vorgenommen. Dieses ist anhand der Amplituden des Nickwinkels identifizierbar. Beispielhaft findet für den Zeitpunkt  $t = 9,12$  Sekunden eine qualitative Reduzierung von 42,87 % statt.

Den Hauptteil des Fahrmanövers bildet die sinusförmige Lenkwinkelvorgabe. Das Nickverhalten für diesen Abschnitt wird analog zur Beschleunigungsphase mit Hilfe des Nickwinkelverlaufs über der Zeit evaluiert. Dieses wird in Abbildung 6 illustriert.

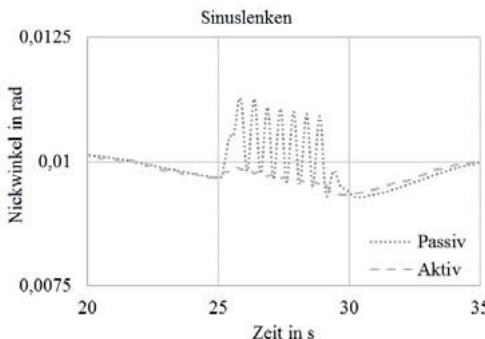


Abbildung 6 Nickwinkelverlauf bei einer sinusförmigen Lenkvorgabe

Grundsätzlich ist zu erkennen, dass die Amplituden des Nickwinkels im Vergleich zu den Vorgängen des Gangwechsels bedeutend kleiner sind. Nichtsdestotrotz ist für das Testfahrzeug mit passiven Fahrwerkselementen eine sinusförmige Schwingung des Nickwinkels zu erkennen. Das Testfahrzeug, welches mit den aktiven Fahrwerkselementen und der nichtlinearen modellbasierten prädiktiven Regelung ausgestattet ist, weist diese Schwingung nicht auf. Durch die gezielte Berücksichtigung des Nickverhaltens im Regelungsalgorithmus konnte der Vorgang des Nickens somit auch bei einer sinusförmigen Lenkwinkelvorgabe verringt werden.

## 5 Zusammenfassung

Im vorliegenden Beitrag wurde eine nichtlineare modellbasierte prädiktive Regelung zur aktiven Wankstabilisierung und Nickreduzierung umgesetzt. Der Regelungsalgorithmus stellt eine Weiterentwicklung des von Sieberg et al. [1] veröffentlichten modellbasierten Regelungsansatzes dar. Die Implementierung erfolgte mit Hilfe einer Co-Simulation aus IPG CarMaker und MATLAB/SIMULINK. Die gesamtheitliche Regelungsaufgabe, bestehend aus Sollgrößenvorgabe, modellbasierter Regelung, Modellierung der Aktuatorverhalten sowie Zustandsschätzer, wurde dabei in MATLAB/SIMULINK umgesetzt. Die Abbildung des Fahrzeuges, insbesondere der Einfluss der Regelung auf die Fahrdynamik sowie Interaktionen zwischen Fahrer, Umgebung und Fahrzeug, wurden mit Hilfe von IPG CarMaker simuliert. Als Versuchsträger wurde ein SUV, ausgestattet mit semiaktiven Stoßdämpfern und aktiven Stabilisatoren, gewählt. Durch den erhöhten Schwerpunkt tendieren Fahrzeuge dieser Klasse schneller zu Wank- und Nickbewegungen. Durch die gewählte Aktuatorik wurde gewährleistet, eine Wankregelung sowie eine Reduzierung des Nickverhaltens erfolgreich durchführen zu können. Die Validierung des weiterentwickelten Regelungsalgorithmus wurde gegenüber dem Testfahrzeug mit passiven Fahrwerkselementen durchgeführt. Das gewählte Fahrmanöver beruht auf einer Sinuslenkvorgabe. Im Rahmen des Beitrages konnte gezeigt werden, dass der nichtlineare modellbasierte prädiktive Algorithmus zur Wankstabilisierung (vgl. [1]) erfolgreich um die

Durchführung der Nickreduzierung erweitert werden konnte. Durch die vereinzelte Betrachtung der semiaktiven Stoßdämpfer konnte das vorhandene Potential zur Verringerung der Nickbewegungen genutzt werden. Der vorgestellte Algorithmus konnte hierbei keine Verschlechterung in der Regelgüte im Vergleich zur reinen aktiven Wankstabilisierung aufweisen. Zusammengefasst beruht diese gezielte gesamtheitliche Einstellung der aktiven Fahrwerkselemente in Bezug auf Wank- und Nickbewegungen auf der Nutzung vorhandener Synergiepotentiale. Daraus resultierten letztendlich eine weitere Komforterhöhung sowie die Steigerung der Sicherheit für die Fahrzeuginsassen. Durch den vorgestellten Aufbau des Algorithmus besteht weiterhin die Möglichkeit, weitere Größen in der Fahrodynamikregelung zu berücksichtigen. Beispielsweise kann über die variable Aufteilung des Konterwankmoments zwischen den Stabilisatoren an Vorder- und Hinterachse das Eigenlenkverhalten gezielt beeinflusst werden.

## 6 Ausblick

Neben der Erweiterung der Regelungsaufgabe um weitere Zielgrößen wird in Zukunft vor allem die echtzeitfähige Umsetzung der vorgestellten nichtlinearen modellbasierten prädiktiven Regelung untersucht. Dieses ist im Hinblick auf eine Implementierung in einem realen Fahrzeug zwingend erforderlich. Durch kostenoptimierte Steuergeräte ist die Rechenkapazität limitiert. In einem weiteren Beitrag werden beispielhaft Methoden der künstlichen Intelligenz dazu verwendet, den vorgestellten Regelungsalgorithmus effizienter auszuführen, ohne dabei die Regelgüte zu beeinflussen. Dabei wird eine Reduzierung der Rechenzeit um den Faktor zwölf erreicht [22].

## 7 Literatur

- [1] P. M. Sieberg, S. Reicherts und D. Schramm, „Nichtlineare modellbasierte prädiktive Regelung zur aktiven Wankstabilisierung von Personenkraftwagen,“ in *IFTOMM D-A-CH Konferenz*, EPFL Lausanne, 2018.
- [2] Aral Aktiengesellschaft, „Trends beim Autokauf 2017,“ Bochum, 2017.
- [3] J. Adamy, *Nichtlineare Systeme und Regelungen*, 2. Auflage Hrsg., Springer, 2014.
- [4] L. Grüne und J. Pannek, *Nonlinear Model Predictive Control*, Springer, 2011.
- [5] D. Schramm, B. Hesse, N. Maas und M. Unterreiner, *Fahrzeugtechnik - Technische Grundlagen aktueller und zukünftiger Kraftfahrzeuge*, De Gruyter Oldenbourg, 2017.
- [6] DIN ISO 8855:2011, *Fahrzeugdynamik und Fahrverhalten - Begriffe*, Deutsches Institut für Normung e.V., 2011.
- [7] D. Schramm, M. Hiller und R. Bardini, *Modellbildung und Simulation der Dynamik von Kraftfahrzeugen*, 2. Auflage Hrsg., Springer, 2013.

- [8] R. Stone, „Simulator studies and psychophysical ride comfort models,“ in *Ride Quality Symposium*, Williamsburg, Virginia, 1975.
- [9] B. Heißen und M. Ersoy, *Chassis Handbook - Fundamentals, Driving Dynamics, Components, Mechatronics, Perspectives*, Vieweg + Teubner, 2011.
- [10] Dr. Ing. h.c. F. Porsche AG, [Online]. Available: [www.porsche.com](http://www.porsche.com).
- [11] N. Laumanns, *Integrale Reglerstruktur zur effektiven Abstimmung von Fahrdynamiksystemen*, Aachen: Forschungsgesellschaft Kraftfahrwesen, 2007.
- [12] T. Kutsche und H. Schürr, „Auf dem Weg zur Systemvernetzung: In welchem Umfang kann ein elektronisches Dämpfungssystem ABS und ESP unterstützen,“ in *Tagung „Fahrwerktechnik“*, München, 2003.
- [13] F. Yu, D.-F. Li und D. Crolla, „Integrated Vehicle Dynamics Control - State-of-the Art Review,“ in *IEEE Vehicle Power and Propulsion Conference*, Harbin, China, 2008.
- [14] R. Isermann, *Fahrdynamik-Regelung - Modellbildung, Fahrerassistenzsysteme, Mechatronik*, Vieweg+Teubner Verlag, 2006.
- [15] W. Chen, H. Xiao, Q. Wang, L. Zhao und M. Zhu, *Integrated Vehicle Dynamics and Control*, John Wiley & Sons Singapore Pte. Ltd, 2016.
- [16] Q. Zhu und B. Ayalew, „Predictive Roll, Handling and Ride Control of Vehicles via Active Suspensions,“ in *American Control Conference*, Portland, Oregon, USA, 2014.
- [17] A. Cromer, „Stable Solutions Using the Euler Approximation,“ *American Association of Physics*, pp. 455-459, 1981.
- [18] ISO, „ISO 13674-1 - Road vehicles - Test method for the quantification of on-centre handling - Part 1: Weave test,“ International Organization for Standardization, 2010.
- [19] ISO, „ISO 7401 - Road vehicles - Lateral transient response test methods - Open-loop test methods,“ International Organization for Standardization, 2011.
- [20] R. Rönitz, H.-H. Braess und A. Zomotor, „Verfahren und Kriterien zur Bewertung des Fahrverhaltens von Personenkraftwagen - Stand und Problematik,“ *Automobil-Industrie*, pp. 29-39; 39-48, 1977.
- [21] A. Zomotor, H.-H. Braess und R. Rönitz, „Verfahren und Kriterien zur Bewertung des Fahrverhaltens von Personenkraftwagen - Ein Rückblick auf die letzten 20 Jahre,“ *Automobiltechnische Zeitschrift*, pp. 780-785, 1997.
- [22] P. M. Sieberg, M. Schmid, S. Reicherts und D. Schramm, „Computation Time Optimization of a Model-Based Predictive Roll Stabilization by Neuro-Fuzzy Systems,“ in *19. Internationales Stuttgarter Symposium - Automobil- und Motorentechnik*, Stuttgart, 2019.



# Identifikation lokal linearer Modelle am Beispiel der Ladedruckstrecke eines Ottomotors

M.Sc. **Stefan Kettlitz**, M.Sc. **Erik Schulz**,  
Dipl.-Ing. **Matthias Schultalbers**,  
IAV Automotive Engineering, Gifhorn

## Systemidentifikation

Ziel dieser Untersuchung ist die Identifikation nichtlinearer Modelle der Ladedruckstrecke eines turboaufgeladenen Ottomotors. Dafür wird der nichtlineare Modellierungsansatz eines linear parameter-variierendes (LPV) Modells gewählt.

Die Identifikation der Ladedruckstrecke wird anhand von Messdaten durchgeführt, die an einem Motorprüfstand aufgenommen werden. Dabei wird mit einer einzigen Identifikationsmessung der gesamte relevante Arbeitsbereich durchfahren, wobei sich der Motor im aufgeladenen Betriebszustand befindet. Der Systemeingang von der Ladedruckstrecke ist die Wastegateposition und der Systemausgang ist der Ladedruck. Der LPV-Ansatz kann als Überblendung linearer zeitinvarianter Modelle verstanden werden, bei dem die Modellkoeffizienten von sogenannten Schedulingparametern abhängen. Physikalische und experimentelle Vorberichtigungen haben ergeben, dass das Systemverhalten von der Drehzahl und dem Ladedruck selbst abhängt, weshalb diese als Schedulingparameter gewählt werden. Hierbei ist darauf hinzuweisen, dass das Scheduling eines Systems über seine Zustandsgrößen, wie den Systemausgang, eine Besonderheit darstellt und die Identifikation erschwert.

Für die LPV-Identifikation muss a priori Wissen über die funktionalen Abhängigkeiten von den Schedulingparametern vorausgesetzt werden. Es ist jedoch möglich den LPV-Ansatz mit dem Verfahren der Support Vector Regression (SVR) zu kombinieren und auf diesem Wege die funktionalen Abhängigkeiten numerisch zu ermitteln.

Für die Identifikation wird zunächst mit dem LPV-SVR-Ansatz aus [1] Untersuchungen in Hinblick auf die funktionalen Abhängigkeiten des Systems von den Schedulingparametern durchgeführt. Anschließend wird mit dem LPV-Ansatz nach [2] und unter Berücksichtigung der mit dem LPV-SVR-Ansatz ermittelten Abhängigkeiten, ein LPV-Modell identifiziert.

Abschließend findet eine Validierung des Modells an verschiedenen Datensätzen mittels Simulation statt. Hierbei werden zwei verschiedene Modellstrukturen betrachtet, um eine Aussage

zur Modellgüte und mögliche Einsatzzwecke zu treffen. In der einen Struktur erfolgt das Scheduling über den Ladedruck anhand eines gemessenen Signals und bei der anderen anhand des Modellausgangs. Eine Validierung mit den gemessenen Signalen ist in Abbildung 1 dargestellt.

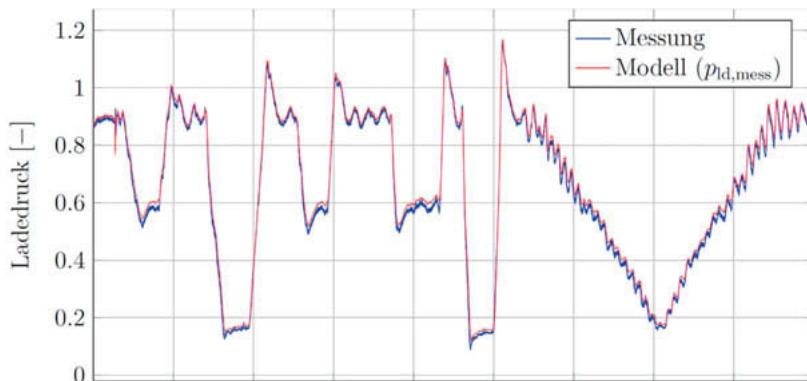


Bild 1: Validierung des LPV-Modells (normiert)

## Literatur

- [1] Smola, Alex J. ; Schölkopf, Bernhard: A tutorial on support vector regression. In: *Statistics and computing* 14, 2004
- [2] Schulz, E. ; Janda, O. ; Schultalbers, M.: On LPV System Identification Algorithms for Input-Output Model Structures and Their Relation to LTI System Identification. In: *System Identification (SYSID), 2018 18th IFAC Symposium on*, 2018, S. 1098–1103

## Generic Sensor Modelling

### A Virtual Integration Approach for the Test of ADAS

M. Eng. **A. Prinz**, BMW Group, München;  
Prof. Dr. rer. nat. **L. Brabetz**, Dr. **M. Ayeb**,  
Universität Kassel

#### Zusammenfassung

Diese Modellierungsmethode basiert auf der Analyse von statistischen Messungenauigkeiten sowie Sensoreffekten im Sensormessraum, welche in einem idealisierten Sensormodell integriert werden. Am Beispiel eines Radarsensors wird die statische Messcharakteristik unter Laborbedingungen empirisch bestimmt und sensortypische Messeffekte in Flottendaten identifiziert. Die Anwendung generisch-adaptiver Modelle an Hardware-in-the-Loop (HiL) Prüfständen bestätigt den Ansatz für die Funktionsabsicherung von Fahrerassistenzsystemen.

#### Abstract

This new developed modelling technique is based on idealistic sensor models adapted with statistical measurement inaccuracies and effects in the sensor measurement space. Using the example of an automotive radar, the statistical measurement analysis is determined by a laboratory setup and typical measurement effects are observed and identified in fleet data. The application of this generic and adaptive model approach on a Hardware-in-the-Loop (HiL) test stand proves the modelling technique for functional testing of driver assistance systems.

#### Generic Sensor Modelling and the Application for the Functional Testing of ADAS

The intended analysis of the radar measurement space (range, velocity, angle and signal energy) includes the application of radar-test-targets like a radar-target-generator with Doppler frequency modulation. The resulting analysis yield to a normal distributed inaccuracy matrix for real target detections in the radar measurement space. In a next step fleet data was analysed for the identification of radar measurement effects that have influence on detection generation, target recognition and therefore the operability of the ADAS system. Following this the associated algorithm uses the false target detections examples to generate simulated false targets according to the scenario. Summarizing what have been said above the idealistic

detections of simulated road users will be biased by the statistical inaccuracy matrix for real target detections. These true positive detections are then reinforced with false targets from algorithms leading over to the ADAS-under-Test. Future research will focus on the modelling of concrete measurement effects for ADAS sensing. This short paper however gives an overview of the process for generic and adaptive modelling by reference to an automotive radar undergirded by real sensor measurements and functional test results.

# Simulation mit Originalsteuerungssoftware im Kundenaustausch

**Michael Mattheai, Matthias Fessler,**  
ZF Friedrichshafen AG, Friedrichshafen

## Zusammenfassung

Die Zeit der Entwicklungszyklen wird seit Jahren verringert. Prototypen werden auf Grund des hohen Zeit- und Kostendrucks nur noch selten den Zulieferern für Fahrzeugtests zur Verfügung gestellt. Zudem wird die eingesetzte Software in vielen Bereichen immer komplexer, kleine Änderungen von Parametern haben oftmals große Auswirkung auf das Gesamtsystem. Ein Weg um diese Software in einer SiL- oder HiL Simulation zu testen kann die virtuelle PC-Integration sein. Hierfür wird die gesamte Steuergerätesoftware (ECU) für einen PC übersetzt. Dies kann exklusiv für eine spezielle Testumgebung passieren oder als unabhängige Functional-Mock-Up-Unit (FMU). Die FMU kann in jeder dafür vorbereiteten Testumgebung eingesetzt werden. Ein großer Vorteil der sich daraus ergibt, ist die Möglichkeit verschiedene Simulationen miteinander zu koppeln.

Diesen Ansatz machte sich ZF Friedrichshafen AG in einer Kooperation mit seinem Kunden zu Nutze. Ein Endprodukt des Kunden besteht aus vielen einzelnen physikalischen- und softwaretechnischen Komponenten unterschiedlichster Hersteller. Jede einzelne Komponente wird vom jeweiligen Hersteller simulativ sehr gut beherrscht. Fremdmodule werden oftmals nur in der Tiefe des vorhanden Fremdwissens simuliert. Um das reale Fahrzeugverhalten inklusive der Reaktionen durch ECU Interaktionen ausreichend genau abbilden zu können, reicht diese Simulationstiefe oftmals nicht aus. Um diese Lücke bei ZF Friedrichshafen AG schließen zu können, findet ein Austausch von physikalischen- und softwaretechnischen Komponenten auf Basis des FMI-Standards statt. Zu beachten gibt es bei diesem Austausch, nur das notwendige Knowhow offenzulegen wofür ZF Friedrichshafen AG einen Verschlüsselungsmechanismus für FMUs entwickelt hat. Um Parameteränderungen an der FMU vornehmen zu können, wurde zudem ein Tool für die Parametrierung der FMU entwickelt. Eine kontinuierliche Validation der Simulationsergebnisse von Kunden- und ZF Friedrichshafen AG sowie der Abgleich mit dem Realfahrzeug führt damit zu einer stetigen Verbesserung der Simulationsqualität. Ein erheblicher Beitrag zu einem noch schnelleren Entwicklungsprozess kann somit durch enge Kooperation von ZF Friedrichshafen AG und ihrem Kunden mit Hilfe der Unternehmensübergreifenden Simulation geleistet werden.



# Learning-Based Path Following Control for an Over-Actuated Robotic Vehicle

**Johannes Ultsch, Dr. Jonathan Brembeck,  
Dr. Ricardo de Castro,**

Institute of System Dynamics and Control, Department for Vehicle System Dynamics, German Aerospace Center, Oberpfaffenhofen

## Kurzfassung

Für autonome Fahrzeuge stellt die Pfadfolgeregelung eine Schlüsselfunktion dar. Die Pfadfolgeregelung steuert hierbei Antrieb, Lenkung und Bremse derart, dass das Fahrzeug einem geometrischen Pfad mit einer Referenzgeschwindigkeit folgt. Für die Auslegung von leistungsfähigen modellbasierten Pfadfolgeregeln wird ein ausreichend genaues Synthesemodell des Fahrzeuges benötigt. Der Entwurf, die Parametrierung und das Testen von modellbasierten Pfadfolgeregeln, sowie das Ableiten eines Synthesemodells ist allerdings eine zeitaufwändige Aufgabe. In der klassischen Regelungstechnik werden deshalb vermehrt Reinforcement Learning (RL) Methoden angewandt, um Regelungsprobleme ohne Synthesemodell, nur mit Hilfe von hochgenauen Simulationsmodellen zu lösen. Um den Einsatz von RL Methoden auf das Pfadfolgeproblem zu untersuchen, wird in diesem Beitrag die Anwendung am Beispiel des überaktuierten robotischen Fahrzeuges ROboMObil des DLRs vorgestellt. Erste Simulationsergebnisse zeigen, dass RL basierte Pfadfolgeregler auf dem Trainingspfad ein ähnlich gutes Folgeverhalten aufweisen, wie modellbasierte Pfadfolgeregler. Die RL basierten Regler erzielen dabei auch auf neuen und unbekannten Pfaden gute Ergebnisse.

## Abstract

Motion control, in particular path following control (PFC), is an important function of autonomous vehicles. PFC controls the propulsion, steering and braking such that the vehicle follows a parametric path and reference velocity. For the design of traditional model-based PFC approaches a sufficiently accurate synthesis model of the vehicle has to be available in order to design a performant controller. However, constructing, parametrizing and testing these model-based PFC as well as deriving the synthesis model is known to be a time-consuming task. Recently the application of reinforcement learning (RL) methods to solve control problems without a synthesis model but based on high fidelity simulation models has gained in-

creasing interest. In this paper we investigate the application of RL methods to solve the path following problem for DLR's ROboMObil, an over-actuated robotic vehicle. Simulation results demonstrate that the RL-based PFC exhibits similar tracking performance as a model-based controller, executed on the path used for training. Moreover the RL-based PFC provides encouraging generalization capabilities, when facing unseen reference paths.

## 1 Introduction

Besides perception and path planning, autonomous driving requires motion control strategies capable of keeping the vehicle on a reference path or trajectory. In order to safely follow the path the aim of the motion controller is to minimize the displacement between the vehicle and a reference path while tracking a desired velocity. This paper focusses on motion control algorithms for path following problems, where the motion demand is characterized by a geometric path description in dependency of the arc length. In contrast to trajectory tracking control, path following control does not require a time-dependent path description.

In previous works, this kind of control problem has been tackled with model-based control methods, where a kinematic or dynamic model of the vehicle is employed to systematically construct the control law, while fulfilling important control requirements, like input and state constraints as well as closed loop robust stability , , , , .

Despite achieving good results, model-based control methods require an accurate synthesis model of the vehicle in order to design and tune the controller. In most cases the complexity of the model used in controller design is however limited by the control method used . For example, widely used linear control methods only perform well if the controlled system is linear or close to linear in the points of operation. Model predictive control (MPC) with a high number of states and nonlinearities requires a high computational effort to solve the optimization problem online. Another drawback of model-based control is the high human effort in the design process, which is time consuming, tedious and error prone.

Recently, it has been shown that reinforcement learning (RL) methods are able to solve a wide variety of control problems, ranging from classical cart pole balancing to flight control for unmanned aerial vehicles and path following of marine vessels . In the model-free reinforcement learning setting no synthesis model is necessary because the control policy is adapted based on observed data and manipulating the control inputs of the system. Similar to model predictive control the control objective is formulated as a numerical reward function (cf. cost function in MPC), which the reinforcement learning agent tries to maximize. The procedure of adapting the control policy based on interaction with the plant is called training and can be done offline in simulation or directly online with the real plant.

In this work we present two variants of RL-based path following controllers which are able to track unknown paths. Additionally, the learning based controllers are compared to a model based controller from previous works within the ROBoMObil project, .

To facilitate the integration of physical models in the training of the RL algorithm, we developed a highly modular training framework based on Python and Functional Mock-up Units (FMU). The FMUs contain the physical model as compiled code and can be created by different modelling tools like Dymola.

The Functional Mock-up Interface (FMI) is an open standard for exchanging physical models between different simulation and modelling tools.

By incorporating one FMU for the vehicle model and one FMU for calculating the reference point on the path a highly modular training framework is achieved and new vehicle configurations can be adapted easily.

## 2 Problem Formulation

In this section the vehicle model, the parametric path representation and the algorithm implemented to determine the reference point on the path are presented.

Throughout this work the frame of reference is denoted by a superscript I, C, P or W for the inertial, car, path and wheel frame, respectively. If the frame of reference is not relevant the superscript is omitted for better readability. The distinction between car and path signals is done by subscripts C or P.

### 2.1 Vehicle Model

The vehicle model incorporated is based on the configuration of DLR's research vehicle RO-BO-MObil (cf. Fig. 1) and consists of a planar two track model including a nonlinear tire model implemented in Modelica using the planar mechanics library . In this setting road height information is neglected and all used reference paths are projected into the xy-plane. The planar mechanics library contains wheel models with different modelling complexity adapted from . The used tire model ("DryFrictionWheelJoint") relies on a semi-empirical formula which considers combined slip and low computational effort. The parameters for the  $\mu$ -slip characteristics of the used tyre model are obtained from real world test data. In the modelling only static vertical loads are considered.

The vehicle can be controlled by commanding the steering angles  $\delta^{W_i}$  of each wheel as well as the torque  $\tau^{W_i}$  of the in-wheel-motors as shown in Fig. 1. The low level control inputs are gathered in  $\mathbf{u} = [\delta^{W_1}, \delta^{W_2}, \delta^{W_3}, \delta^{W_4}, \tau^{W_1}, \tau^{W_2}, \tau^{W_3}, \tau^{W_4}]$  and are used to control the three planar degrees of freedom of the car. Since the dimension of the control inputs exceeds the

degrees of freedom, the control problem is over actuated and a control allocation needs to be applied.

The vehicle velocity  $v_C^C = [v_{C,x}^C, v_{C,y}^C]$  in the car frame of reference as well as the tire forces  $F^{W_i} = [F_x^{W_i}, F_y^{W_i}]$  in the wheel frame of reference are also depicted in Fig. 1.

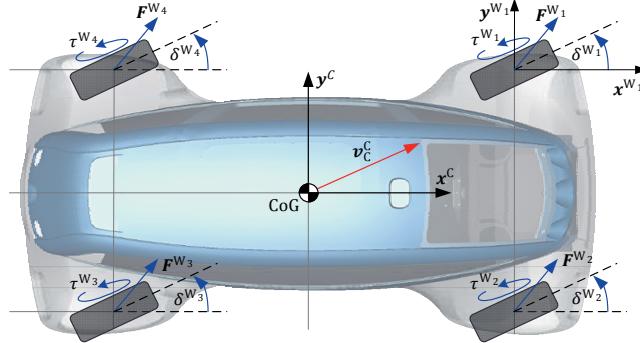


Fig. 1: Vehicle configuration of DLR's ROboMObil

Due to the fast time-response of the in-wheel-motors their dynamics are neglected in the model. The dominant dynamics of the steering actuator is approximated by a second order system (Bessel filter with critical frequency of 15 Hz) and the maximum actuator rate is limited by  $|\delta^{W_i}| \leq 60^\circ/s, i \in \{1, \dots, 4\}$ . All vehicle parameters are summarized in .

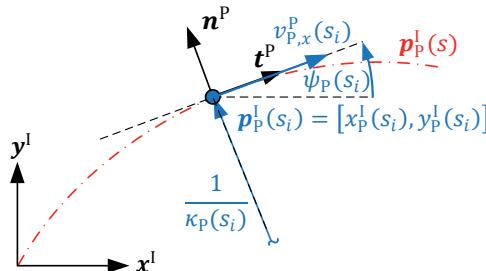
## 2.2 The Parametric Path Description

The interface to the path following control is a motion demand parametrized by the path arc length  $s: \lambda(s) \in \mathbb{R}^5$ . It consists of the following five quantities: the absolute estimate  $p_p^1$   $[x_p^1(s), y_p^1(s)]$  of the reference path, the corresponding path orientation  $\psi_p(s)$ , its curvature  $\kappa_p(s)$  and a desired longitudinal velocity  $v_{p,x}^p(s)$ :

$$\lambda(s) = [x_p^1(s), y_p^1(s), \psi_p(s), \kappa_p(s), v_{p,x}^p(s)] \quad (1)$$

Fig. 2 depicts an example of the motion demand at the point  $s_i$ . Note that the desired vehicle longitudinal velocity  $v_x^p(s_i)$  is in the direction of the tangent vector  $t^p$  at  $p_p^1(s_i)$ . The normal vector  $n^p$  is orthogonal to  $t^p$  and spans together with  $t^p$  the path frame of reference.

Since path planning is out of the scope of this contribution it is assumed that a parametric path is available in form of a lookup table. An overview of online path planning for the ROboMObil is given in .

Fig. 2: Graphical interpretation of the parametric path  $\lambda(s)$  at point  $s_i$ 

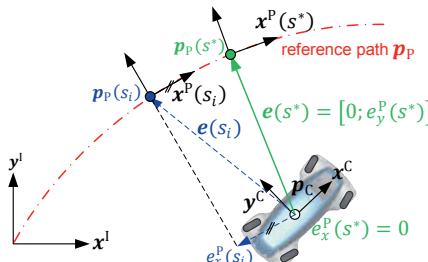
### 2.3 Time Independent Path Interpolation (TIPI)

Consider the vehicle position  $p_c$  as depicted in Fig. 3. In order to implement the PFC we need to find the closest point between  $p_c$  and the reference path  $p_p$ . In other words, we need to find  $s$  where the distance  $e(s) = p_p(s) - p_c$  between the path and the position of the car is minimal, i.e.

$$s^* = \arg \min_s \left\| \underbrace{p_p(s) - p_c}_{e(s)} \right\|_2. \quad (2)$$

The geometrical interpretation of this minimization objective is that  $p_p(s^*)$  can be determined by projecting  $p_c$  orthogonally on the path  $p_p(s)$  which yields that the x-coordinate of the position error in the path frame is zero:  $e_x^p(s^*) = 0$  (cf. Fig. 3).

It is assumed that the initial vehicle position  $p_c^I$  is sufficiently accurately estimated by a vehicle position estimator e.g., as proposed . The optimization problem (2) is solved by means of a time independent path interpolation (TIPI), which is adopted from, .

Fig. 3: Graphical representation of the dynamic root finding to determine  $s^*$

As stated in  $\mathbf{p}_P(s^*)$  exists and is unique if  $e_y^P(s^*) \leq 1/\kappa_P(s^*)$ . With the origin of the path frame of reference located in  $\mathbf{p}_P(s^*)$  the errors represented in the path frame, which will be used later in the controller setup, can be calculated as follows:

$$\begin{aligned} e_y^P &= \underbrace{y_P^P - y_C^P}_= \\ e_{v_x}^P &= v_{P,x}^P - v_{C,x}^P \\ e_{v_y}^P &= \underbrace{v_{P,y}^P - v_{C,y}^P}_= \\ e_\psi &= \psi_P - \psi_C. \end{aligned} \quad (3)$$

### 3 Reinforcement Learning based Path Following Control

In the beginning of this section a general reinforcement learning setting is described and the chosen RL algorithm is discussed briefly. After this the whole structure of the RL-based PFC is presented and the incorporated interfaces are explained. In the end details on the implementation are given.

#### 3.1 Reinforcement Learning Setting

In the reinforcement learning setting it is assumed that the controlled environment can be described as a Markov decision process (MDP) with a continuous set of states  $s \in \mathcal{S}$  and a continuous set of actions  $a \in \mathcal{A}$  (cf. ). The probability for transitioning from a state  $s_t$  at time step  $t$  to the state  $s_{t+1}$  at time step  $t+1$  by taking action  $a_t$  is given by a state transition probability  $p(s_t, s_{t+1}, a_t): \mathcal{S} \times \mathcal{S} \times \mathcal{A} \rightarrow [0, \infty)$  and a reward  $r(s_t, a_t): \mathcal{S} \times \mathcal{A} \rightarrow \mathbb{R}$  is received at each transition.

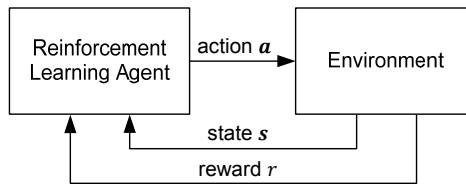


Fig. 4: Reinforcement learning setting

The standard objective in reinforcement learning is to find an optimal stochastic control policy  $\pi^*(a_t|s_t)$  such that the expected sum of rewards

$$G = \sum_t \mathbb{E}_{(s_t, a_t) \sim \rho_\pi} [r(s_t, a_t)] \quad (4)$$

is maximized with  $\rho_\pi(s_t, a_t)$  denoting the state-action marginal of the trajectory distribution induced by the stochastic policy  $\pi(a_t|s_t)$  and expectation  $\mathbb{E}$  (cf. ). After the training process

the stochastic policy is transformed into a deterministic policy by taking the expected value at each state  $s_t$ .

In *model-free* reinforcement learning it is assumed that the environment is unknown and the policy is learned out of interaction between the agent and the environment as shown in Fig. 4. During training the agent adapts the policy to maximize the reward (exploitation) by still acting random enough to explore for potentially better solutions (exploration).

Recently several algorithms have been published which aim to solve this problem incorporating artificial neural nets, . In our work we chose the Soft Actor-Critic (SAC) algorithm because of its stable behavior during training and its robust training over a wide range of hyper parameters. In reinforcement learning, parameters like the number of time steps considered for training, which parametrize the RL algorithm are called hyper parameters. It has been shown that in addition to that SAC achieves similar performance than other RL algorithms.

In SAC the objective to maximize the expected sum of rewards is augmented by an entropy term which considers exploration by design :

$$\pi^* = \arg \max_{\pi} \sum_t \mathbb{E}_{(s_t, a_t) \sim \rho_{\pi}} [r(s_t, a_t) + \alpha \mathcal{H}(\pi(\cdot | s_t))] \quad (5)$$

with the information-theoretical entropy  $\mathcal{H}(X)$  (cf. ).

The relative importance between the maximization of the return and the maximization of the entropy is adjusted by the temperature parameter  $\alpha$ . In an enhanced version of the SAC, which is used in this contribution, the temperature parameter is selected automatically during training which minimizes the effort of hyper parameter tuning .

### 3.2 Application of Reinforcement Learning to the Path Following Problem

To reduce the problem complexity we split the PFC problem into a path following and a control allocation problem. We then use RL to solve the path following problem.

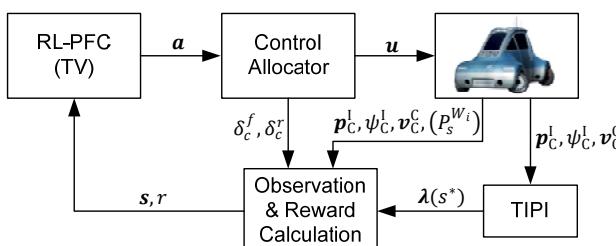


Fig. 5: Reinforcement Learning based PFC setup

As shown in Fig. 5 a control allocator maps the actions  $\mathbf{a}$  commanded by the RL algorithm to the vehicle inputs  $\mathbf{u}$ . In order to gain insights in the ability of RL to deal with over actuation we designed two variants of RL-based PFCs and compare them (cf. section 3.2.1 and 3.2.2). Since RL works in discrete time the system is sampled with sample time  $T_s = 0.05$  s

### 3.2.1 Basic Reinforcement Learning based Path Following Control (RL-PFC)

In the first version (RL-PFC) the action space of the RL is selected such that front axle steering angle  $\delta_t^f$ , rear axle steering angle  $\delta_t^r$  and average in-wheel motor torque  $\tau_t$  can be commanded:  $\mathbf{a}_t = [\delta_t^f, \delta_t^r, \tau_t]$ . The control allocator then distributes the desired torque equally to all wheels:  $\tau_t = \tau_t^{W_1} = \tau_t^{W_2} = \tau_t^{W_3} = \tau_t^{W_4}$ . Since the steering actuators can only realize a certain steering rate  $\dot{\delta}_{\max}$  the commanded steering angles  $\delta_t^f$  and  $\delta_t^r$  are constrained by the control allocator in each time step  $t$ :  $\delta_{c,t}^i = f_{\text{clip}}(\delta_t^i, \delta_{c,t-1}^i, \dot{\delta}_{\max})$  for  $i \in \{f, r\}$  with

$$f_{\text{clip}}(x_t, x_{t-1}, \dot{\delta}_{\max}) = \begin{cases} x_t, & \text{if } |x_t - x_{t-1}| \leq T_s \dot{\delta}_{\max} \\ x_{t-1} + T_s \dot{\delta}_{\max}, & \text{if } x_t - x_{t-1} > T_s \dot{\delta}_{\max} \\ x_{t-1} - T_s \dot{\delta}_{\max}, & \text{if } x_t - x_{t-1} < -T_s \dot{\delta}_{\max}. \end{cases} \quad (6)$$

The clipped front and rear axle steering angles  $\delta_{c,t}^f$  and  $\delta_{c,t}^r$  are then allocated according to the Ackermann steering assumption such that all wheels have the same instantaneous center of rotation (ICR). For the calculation it is assumed that  $\delta_{c,t}^f$  steers a virtual wheel in the middle of the front axle and  $\delta_{c,t}^r$  a virtual wheel in the middle of the rear axle. The intersection of the orthogonal lines onto this virtual wheels uniquely define the ICR and the steering angles  $\delta_t^{W_1}, \delta_t^{W_2}, \delta_t^{W_3}, \delta_t^{W_4}$  can be calculated. If  $\delta_{c,t}^f$  and  $\delta_{c,t}^r$  have the same value, the ICR moves to infinity and this value is applied to each wheel.

### 3.2.2 Reinforcement Learning based Path Following Control with Torque Vectoring (RL-PFC TV)

To investigate how the RL algorithm deals with over-actuation a second variant is designed (RL-PFC TV). In this variant the action vector  $\mathbf{a}_t$  is extended with the torque demands of each wheel:  $\mathbf{a}_t = [\delta_t^f, \delta_t^r, \tau_t^{W_1}, \tau_t^{W_2}, \tau_t^{W_3}, \tau_t^{W_4}]$ . This gives the RL agent the possibility to utilize torque vectoring (TV) and no control allocation for the wheel torques is necessary. The steering angles are again distributed as in the RL-PFC variant described in section 3.2.1.

### 3.2.3 Reward Function for Path Following Control

Besides selecting the RL hyper parameters, design choices have to be made by formulating the reward function as well as selecting the observation vector  $\mathbf{s}$ . Similar to the cost function in model predictive control the reward function should be designed such that fulfilling the control goal yields a high scalar reward (cf. low cost in MPC).

In the construction of the reward functions we make use of a dead zone-based function  $h_\beta(x)$  inspired by

$$h_\beta(x) = \begin{cases} 0, & \text{if } |x| < \beta_1 \\ -\beta_2 \cdot |x|, & \text{else} \end{cases} \quad (7)$$

and of a Gaussian-like function  $g_\theta(x)$  inspired by

$$g_\theta(x) = \theta_1 e^{\frac{-x^2}{2\theta_2^2}}. \quad (8)$$

It should be noted that  $g_\theta(x)$  fulfills

$$0 < g_\theta(x) \leq \theta_1, \forall x \in \mathbb{R}, \forall \theta_1, \theta_2 \in \mathbb{R}^+ \quad (9)$$

which is used later.

The main control goal of the PFC is to keep the vehicle close to the path ( $e_y^P \rightarrow 0$ ) because deviation from the demanded path might possibly compromise safety e.g. collisions with obstacles. As secondary goals, we consider the minimization of the orientation error  $e_\psi$  and longitudinal velocity error  $e_{v_x}^P$ .

To achieve this behavior the following reward function, inspired by and , is designed for the RL-PFC:

$$r_{\text{RL-PFC}}(e_y^P, e_\psi^P, e_{v_x}^P, \Delta\delta^f, \Delta\delta^r) = r_e(e_y^P, e_\psi^P, e_{v_x}^P) + r_{\Delta\delta}(e_y^P, \Delta\delta^f, \Delta\delta^r). \quad (10)$$

Herein  $\Delta\delta_t^i$  denotes the difference between the commanded steering angle and the clipped steering angle from the last time step  $t - 1$ :  $\Delta\delta_t^i = \delta_t^i - \delta_{c,t-1}^i$  for  $i \in \{f, r\}$ . The reward function  $r_{\text{RL-PFC}}$  is composed of two terms  $r_e$  and  $r_{\Delta\delta}$ . The first one accounts for tracking errors while the second one penalizes control jittering in the steering angles.

The first term  $r_e$  is chosen as follows, extended from :

$$r_e(e_y^P, e_\psi^P, e_{v_x}^P) := g_{\theta_e}(e_y^P) \left( 1 + g_{\theta_\psi}(e_\psi^P) + g_{\theta_v}(e_{v_x}^P) \right) \quad (11)$$

with the Gaussian-like function  $g_\theta(x)$  defined in (8). Here the parameter  $\theta_{e,1}$  is set to  $\theta_{e,1} := 1$  such that  $0 < g_{\theta_e}(e_y^P) \leq 1$  for all  $e_y^P \in \mathbb{R}$ .

Since  $g_{\theta_\psi}(e_\psi^P)$  and  $g_{\theta_v}(e_{v_x}^P)$  are also bounded from above by  $\theta_{\psi,1}$  and  $\theta_{v,1}$  the whole term  $r_e$  tends to 0 for large position errors  $e_y^P$ . For small position errors  $e_y^P$  the value of  $g_{\theta_e}(e_y^P)$  tends to 1 and the summands  $g_{\theta_\psi}(e_\psi^P)$  and  $g_{\theta_v}(e_{v_x}^P)$  determine the value of  $r_e$ . This means that the term  $r_e$  takes its maximum for zero tracking errors  $0 = e_y^P = e_\psi^P = e_{v_x}^P$  and tends to 0 if  $e_y^P$  is large. Additionally, the orientation error  $e_\psi^P$  and velocity error  $e_{v_x}^P$  dominate the value only if the position error  $e_y^P$  is small.

Designing the first term of the reward function (10), as proposed in equation (11), considers the position tracking as the primary control goal and velocity and orientation tracking as secondary goals. This fulfills the requirements for PFC which are described above. The second term of (10) is chosen to penalize large control jittering:

$$r_{\Delta\delta}(e_y^p, \Delta\delta^f, \Delta\delta^r) := g_{\theta_{\Delta\delta}}(e_y^p) \left( h_{\beta_{\Delta\delta}}(\Delta\delta^f) + h_{\beta_{\Delta\delta}}(\Delta\delta^r) \right). \quad (12)$$

The parameter  $\theta_{\Delta\delta,1}$  is chosen as  $\theta_{\Delta\delta,1} := 1$  such that the summands in the parenthesis of equation (12) are scaled by a factor between 0 and 1 depending on the position error  $e_y^p$ . As in the design of  $r_e$  this accounts for position tracking being the main control goal. The term  $h_{\beta_{\Delta\delta}}(\Delta\delta^i)$ , with a dead zone-based function  $h_{\beta}$  according to (7), adds a negative value if the commanded steering angle  $\delta_t^i$  exceeds the last clipped steering angle  $\delta_{c,t-1}^i$  in magnitude by a margin  $\Delta\delta_{\text{lim}} := \beta_{\Delta\delta,1}$ , which guides the RL agent to favor smooth commanded steering angles.

For the variant with torque vectoring (RL-PFC TV) the reward function presented in (10) is augmented by an additional term penalizing the loss power  $P_s^{W_i}$  induced by the slip at each wheel:

$$\begin{aligned} r_{\text{RL-PFC TV}}(e_y^p, e_\psi^p, e_{v_x}^p, \Delta\delta^f, \Delta\delta^r, P_s^{W_1}, P_s^{W_2}, P_s^{W_3}, P_s^{W_4}) \\ = r_{\text{RL-PFC}}(e_y^p, e_\psi^p, e_{v_x}^p, \Delta\delta^f, \Delta\delta^r) - d_1 \underbrace{\sum_{i=1}^4 \left( \frac{P_s^{W_i}}{d_2} \right)^2}_{r_{P_s}} \end{aligned} \quad (13)$$

with parameters  $d_1, d_2 > 0$ . The loss power can be calculated as follows:

$$P_s^{W_i} = \mathbf{F}^{W_i} \cdot \mathbf{v}_s^{W_i} \quad \text{with } i \in \{1, 2, 3, 4\} \quad (14)$$

with  $\mathbf{v}_s^{W_i} = [v_{s_x}^{W_i}, v_{s_y}^{W_i}]$  denoting the slip velocity vector and  $\mathbf{F}^{W_i}$  the contact force vector at wheel  $i$  (cf. Fig. 1) with  $\mathbf{v}_s^{W_i}$  and  $\mathbf{F}^{W_i}$  dependant on  $\mathbf{a}$ .

This augmentation guides the choice of the additional degrees of freedom in the RL-PFC TV compared to the RL-PFC. In contrast to all terms in  $r_{\text{RL-PFC}}$  (cf. equation (11) and (12)), the additional term in (13) is not multiplied by a term accounting for position tracking. This multiplier is dropped to guide the control allocation within the RL agent in an early stage of the training process, where position tracking is not accurate yet.

### 3.2.4 Observation Vector

The observation vector  $s_t$  which is fed back into the RL agent is composed of the errors defined in (3), the path curvature  $\kappa_{p,t}$  as well as the clipped steering angles  $\delta_{c,t}^f$  and  $\delta_{c,t}^r$  at time

step  $t$ . Since no memory is present in the policy the observation vector  $s_t$  is augmented by the values of the last time step  $t - 1$ , yielding:

$$s_t = [e_{y,t}^p, e_{v_x,t}^p, e_{v_y,t}^p, e_{\psi,t}, \kappa_{p,t}, \delta_{c,t}^f, \delta_{c,t}^r, e_{y,t-1}^p, e_{v_x,t-1}^p, e_{v_y,t-1}^p, e_{\psi,t-1}, \kappa_{p,t-1}, \delta_{c,t-1}^f, \delta_{c,t-1}^r] \quad (15)$$

Augmenting the observation vector with the values of the last time step brings rate information to the RL agent. It is also necessary to feed back the current clipped steering angles  $\delta_{c,t}^f$  and  $\delta_{c,t}^r$  to enable the RL agent to learn to drive smooth and avoid jittering in the commanded steering angles.

### 3.3 Implementation Details of the Training Framework

The PFC problem was implemented by using the interface from OpenAI Gym and the SAC implementation from the stable-baselines . As depicted in Fig. 6 the vehicle model and the time independent path interpolation were implemented in Modelica, exported as FMU by Dymola and included in the Python framework. Utilizing two different FMUs enables a highly modular training framework and new vehicle configurations can be easily adapted.

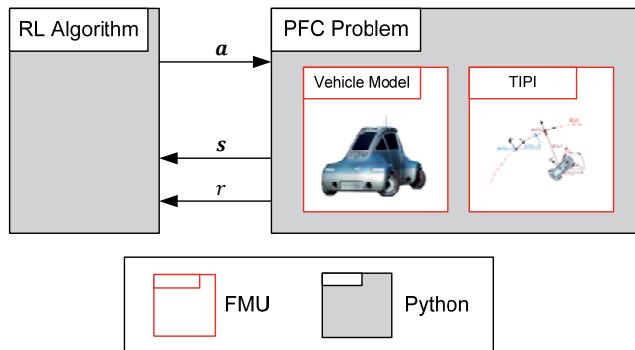


Fig. 6: RL-PFC implementation setup

The whole framework was implemented on a desktop PC with an Intel Xeon W-2135 CPU @ 3.70GHz and a Nvidia Quadro P600 [GP107GL] graphics card with openSUSE Leap 42.3 as operating system.

## 4 Simulative Assessment and Comparison

In this section the performance of the RL-PFC and RL-PFC TV controllers are evaluated and compared to a PFC reference controller.

The reference path following controller (later called ref PFC) used in this chapter is based on previous work in [6]. To fulfil the control goal, a cascaded structure with three separate PD controllers stabilizing the position  $e_y^P$ , velocity  $e_{v_x}^P$  and orientation  $e_\psi$  tracking error in the outer control loop is used in the ref PFC. In the inner control loop an optimization based control allocator was implemented in the reference controller. Details on the implementation are omitted here due to sake of brevity; the interested reader is referred to [6] for details.

## 4.1 Training of the RL-based Controller

For training the RL-based PFC a track on ADAC testing ground in Kempten is chosen (cf. Fig. 7a). The planned path on this test track is very demanding, includes tight and wide turns as well as straight lines and is, therefore, suited to expose the two RL-based PFC variants to challenging driving maneuvers during training.

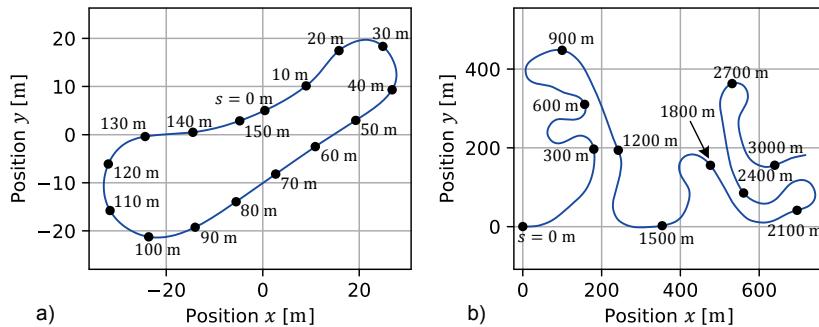


Fig. 7: a) Path used for training, b) Path used to show generalization

To avoid exploration of non-relevant regions and to guide the training, an episode is aborted if the vehicle exceeds certain position errors, orientation errors, etc. The abortion criteria have to be chosen carefully and are subject to a trade-off: On the one hand, early abortion guides the reinforcement learning and, therefore, a faster convergence during the training is given and thus shorter training times can be achieved. On the other hand, early abortion limits the room for exploring the observation space and, therefore, limits the robustness of the obtained controller. For our problem the following abortion criteria have been found to be convenient: An episode is aborted and a terminal reward of  $r_T = -10$  is fed back if one of the following conditions is fulfilled:  $|e_y^p| > 2 \text{ m}$ ,  $|e_\psi| > 80^\circ$ ,  $|e_{v_x}^p| > 2 \frac{\text{m}}{\text{s}}$ ,  $|e_{v_y}^p| > 5 \frac{\text{m}}{\text{s}}$ ,  $|v_C| < 1 \frac{\text{m}}{\text{s}}$ . If an

episode is aborted the vehicle is reinitialized at the abortion arc length. At the first episode and if the vehicle reaches the end of the path the vehicle is initialized at  $s = 0$  m.

In reinforcement learning randomness in the initialization of the plant supports the exploration of the observation space. Therefore, the vehicle is initialized according to the desired motion demand  $\lambda(s)$  with some extra offset at the beginning of an episode. The offset is drawn from a uniform distribution within the following limits:

$$\begin{aligned} -1.4 \text{ m} &< e_{y,\text{start}}^P < 1.4 \text{ m} \\ -24^\circ &< e_{\psi,\text{start}} < 24^\circ \\ -1 \frac{\text{m}}{\text{s}} &< e_{v_x,\text{start}}^P < 1 \frac{\text{m}}{\text{s}} \end{aligned} \quad (16)$$

It should be noted that choosing the limits too wide can result in situations where the abortion criteria will be violated no matter which input is chosen by the RL agent. Choosing the limits very restrictive will result in less exploration and, therefore, might yield a less robust controller.

In our use case the RL-PFC was trained with 300,000 and the RL-PFC TV variant with 400,000 time steps, which took 1h 15min and 1h 40min respectively. Fig. 8 depicts the episode return of the RL-PFC TV variant, which is the sum over all rewards during one episode, and the episode length, which is the number of time steps of one episode.

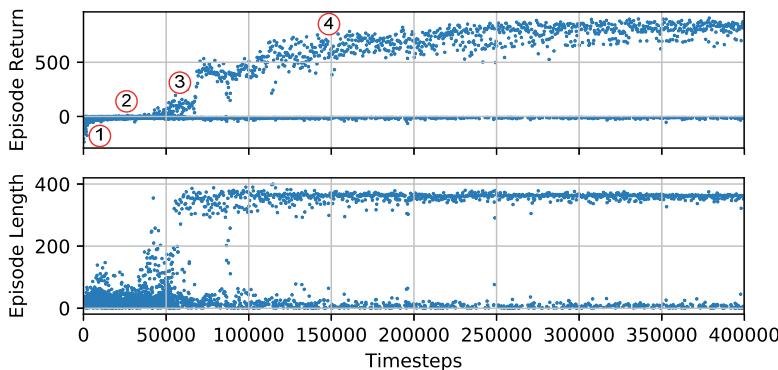


Fig. 8: Episode Length and Reward during training of RL-PFC TV

The training process can be divided into 4 different phases. In phase 1 the episode return is well below  $-10$  and the episode lengths are short. The short episode length can be explained by early abortion due to violation of one of the abortion criteria defined above. This

means that the agent is not able to solve the PFC task in the beginning. The low episode returns can be explained as follows: The terminal reward  $r_T = -10$  can only be emitted once at the end of the episode and therefore all episode returns below  $-10$  are caused by negative summands in the reward function (13). Since the only summands which can take negative values are  $r_{\Delta\delta}$  and  $r_{P_s}$  they make up for the negative episode returns in the first phase caused by a jittery steering control and high slip losses.

By transitioning to phase 2 the RL agent learns to avoid jittery control and slip losses. Nevertheless, the agent still cannot master the task properly. This can be concluded based on the small episode returns as well as the short episode lengths during the second phase.

In phase 3 the algorithm more and more learns to solve the task, which can be seen in the longer episodes and higher returns.

During phase 4 the control policy is further improved to achieve higher rewards. In this phase the episode length and returns divide into two branches. One branch which stabilizes on a high level and one which is close to 0. The reason for the short episodes lies in cases where the vehicle is initialized in a challenging way and the exploratory behavior of the RL algorithm. As explained above this initialization is kept because more robust controllers could be obtained this way.

#### 4.2 Comparison of the RL-PFC Variants with the Reference Controller on the Training Path

Table 1 shows the root mean square error (RMSE:  $\sqrt{\frac{1}{s_{\max}} \int_0^{s_{\max}} (e(s))^2 ds}$ ) and the maximum absolute error ( $\max_s |e(s)|$ ) of the two learning based controller variants with (RL-PFC TV) and without (RL-PFC) torque vectoring when executed on the path used for training (cf. Fig. 7a). To assess the performance of the learning-based controllers, the errors of the reference controller (ref PFC) are displayed as well. To evaluate the performance properly, the vehicle is initialized at  $s = 0$  according to the motion demand  $\lambda(s = 0)$  with all errors equal to zero:  $e_y^p = 0$ ,  $e_{v_x}^p = 0$ ,  $e_\psi = 0$ .

Table 1: RMSE and maximum error on the training path with initialization according to the motion demand ( $e_y^P = 0$ ,  $e_{v_x}^P = 0$ ,  $e_\psi = 0$ )

		RL-PFC TV	RL-PFC	ref PFC
$e_y^P$ [cm]	RMSE	<b>1.41</b>	1.60	2.39
	max	4.19	<b>3.55</b>	9.99
$e_{v_x}^P$ [m/s]	RMSE	0.165	0.174	<b>0.0965</b>
	max	0.413	0.526	<b>0.383</b>
$e_\psi$ [°]	RMSE	1.39	<b>0.679</b>	0.964
	max	3.39	<b>1.38</b>	2.66

From Table 1 it can be seen that both learning based controller variants are able to outperform the reference controller on the position error  $e_y^P$  on both error scales (RMSE and max). On the other hand, the velocity tracking performance of both RL variants is worse than the reference controller (cf. Table 1). Both RL-PFC variants sacrifices velocity error in term of reduced position error. This originates in the selected reward function where we chose minimizing the position error to be the main priority. Nevertheless, the velocity tracking of learning based controllers is within the same number of magnitude as the ref PFC.

Even though position tracking was the main control goal the RL-PFC variant is able to outperform the ref PFC in minimizing the orientation tracking. On this path the RL-PFC TV is performing slightly worse in terms of orientation tracking than the ref PFC.

Overall the RL-PFC TV performs quiet similar compared to the RL-PFC variant which means that the RL-PFC TV is not able to exploit the additional degrees of freedom but is still able to allocate the degrees of freedom in the action space such that it can fulfil the PFC task.

#### 4.3 Robustness Against an Initial Offset on the Training Path

To show PFC's ability to compensate for initial lateral position errors the vehicle was initialized with an initial lateral offset of  $e_y^P = -0.4$  m on the path used for training (cf. Fig. 7a). All other states have been initialized according to the motion demand with  $e_{v_x}^P = 0$  and  $e_\psi = 0$ . In Fig. 9 the lateral position error  $e_y^P$ , longitudinal velocity error  $e_{v_x}^P$  and the orientation error  $e_\psi$  of all three controller variants are depicted.

It can be seen from Fig. 9 that all controller variants need approximately 20 m to eliminate the initial position tracking error.

Right after the recovery the vehicle has to follow the first sharp turn, which begins at approximately  $s = 20$  m and ends at approximately  $s = 45$  m, leading into the long straight until ap-

proximately  $s = 90$  m (cf. Fig. 7a). It can be observed that both RL-PFC variants are able to track the path more accurately during the demanding first turn and during the first part of the straight. From the velocity profile it can be seen that the RL-PFC variants achieve the more accurate position tracking by adjusting the speed and therefore sacrifices velocity error in term of reduced position error. Since the position tracking is our main control goal we encouraged this kind of behavior by the design of the reward function described in section 3.2.3. The chosen reference controller is not able to deal with competing objectives since three separate PD controllers are used for position, velocity and orientation tracking.

It should be remarked that while driving on the straight between  $s = 60$  m and  $s = 80$  m a steady orientation error can be observed in all three applied controllers. Because of the over actuated vehicle architecture depicted in Fig. 1 it is possible to drive with an orientation error while maintaining the position error.

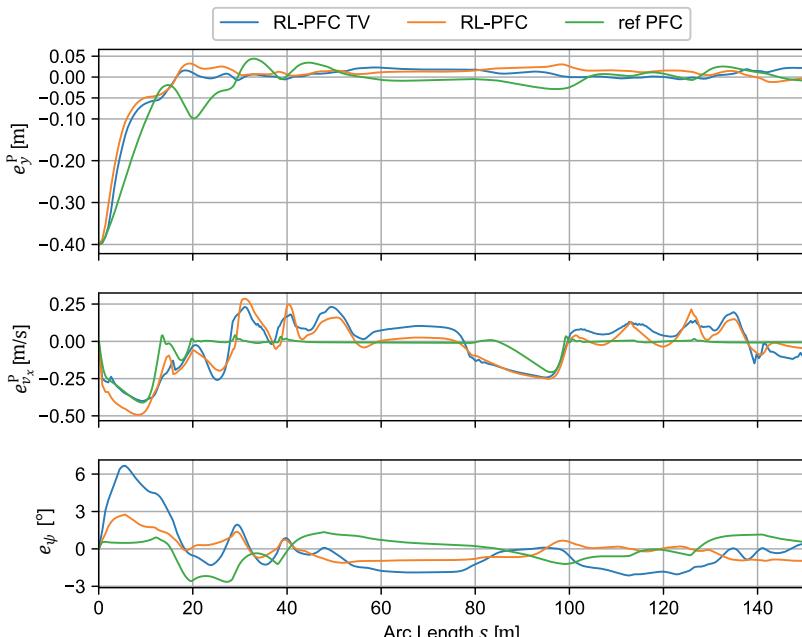


Fig. 9: Tracking errors on the training path with initial position error:  $e_y^P = -0.4$  m

The clipped commanded front- and rear axle steering angles  $\delta_c^f$  and  $\delta_c^r$  for driving on the training path are shown in Fig. 10. Since the reference PFC variant does not use the virtual control inputs  $\delta^f$  and  $\delta^r$  the average steering angle from the left and right hand side for the front and rear axles are used for comparison:  $\delta_{\text{ref}}^f = \frac{\delta^{W_1} + \delta^{W_2}}{2}$  and  $\delta_{\text{ref}}^r = \frac{\delta^{W_3} + \delta^{W_4}}{2}$ . It can be observed that the overall control strategy of all three variants are quiet similar even though no a priori knowledge about the distribution of the steering angles had been fed into the RL-PFC design process.

Overall it can be concluded that in our example both RL-PFC could show its benefits especially in the most challenging driving situation which is the first sharp turn on our training course. Besides being able to handle the tradeoff between position-, velocity- and orientation tracking the RL-PFC variants do not rely on linear behavior and therefore can exploit the nonlinearity in this challenging driving situation.

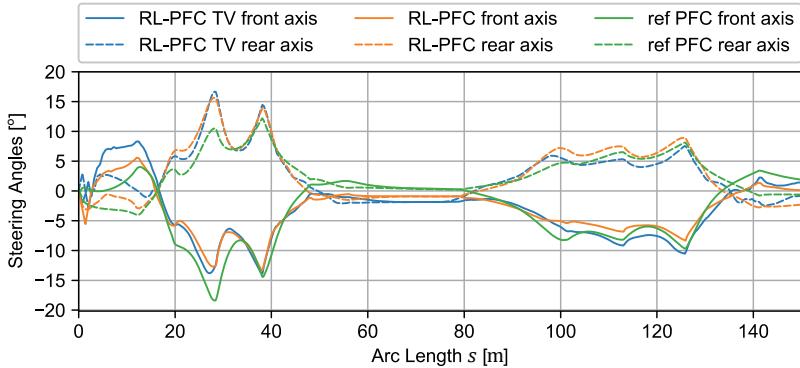


Fig. 10: Steering angles on the training path with initial position error:  $e_y^P = -0.4$  m

#### 4.4 Evaluation of Generalization Capabilities of the RL-PFC Variants

In this section all control approaches are compared on a curvy road which is “unknown” to the learning based controller variants and is shown in Fig. 7b. Similar to the evaluation described in section 4.2 the vehicle is initialized with zero errors ( $e_y^P = 0$ ,  $e_{v_x}^P = 0$ ,  $e_y = 0$ ) according to the motion demand  $\lambda(s = 0)$ . The RMSE and maximum errors are shown in Table 2.

Table 2: RMSE and maximum error on a curvy road with initialization according to the motion demand ( $e_y^P = 0$ ,  $e_{v_x}^P = 0$ ,  $e_\psi = 0$ )

Errors		RL-PFC TV	RL-PFC	ref PFC
$e_y^P$ [cm]	RMSE	1.47	1.54	<b>0.172</b>
	max	2.59	3.51	<b>0.579</b>
$e_{v_x}^P$ [m/s]	RMSE	0.130	0.142	<b>0.00652</b>
	max	0.311	0.314	<b>0.0140</b>
$e_\psi$ [°]	RMSE	0.866	0.813	<b>0.121</b>
	max	2.29	1.39	<b>0.354</b>

Even though the curvy road is unknown to the RL-PFC variants, both RL-based controllers are able to follow the path with tracking error  $|e_y^P| < 3.6$  cm, velocity error  $|e_{v_x}^P| < 0.35 \frac{\text{m}}{\text{s}}$  and orientation error  $|e_\psi| < 2.3^\circ$ .

Still the reference controller is able to outperform the RL-based controllers on the curvy road. This can be explained by the fact that the path on the curvy road is a lot less challenging than the path used for training. Since the RL-PFC variants are exposed to a different motion profile in terms of curvature, velocity and orientation this region of the observation space is not well explored during training. Besides that, in section 4.3 it could be observed that RL has shown its advantage especially in challenging driving situations which are not present on the curvy road.

Even though only one path profile and a relative small number of training time steps was used for training the maximum position, velocity and orientation errors of the RL-PFC variants are within an acceptable range. To further improve generalization, the RL-PFC variants must be exposed to a greater variety of driving situations.

Moreover, it can be observed that the performance of the RL-PFC TV and the RL-PFC on all metrics displayed in Table 2 is quiet similar. This backs the observation from section 4.2 that the RL-PFC TV is not able to exploit the additional degrees of freedom in the action space but is still able to construct a control law such that an unknown path can be followed.

## 5 Conclusion and Outlook

In this work it has been shown that reinforcement learning-based path following controllers are able to outperform a model based reference controller on the path used for training. Both proposed RL-based controllers could minimize an initial position error of  $e_y^P = -0.4$  m.

Despite training the RL-based path following controllers only on one path with one velocity profile they are able to follow an unknown path with a position, velocity and orientation error of  $|e_y^P| < 3.6 \text{ cm}$ ,  $|e_{v_x}^P| < 0.35 \frac{\text{m}}{\text{s}}$  and  $|e_\psi| < 2.3^\circ$ , respectively.

Even though no human effort is necessary during training it should be noted that finding an appropriate reward function and hyper parametrization for the RL algorithm is not straight forward and includes trial and error. Another drawback is that for RL based controllers no formal stability guarantees can be derived yet.

The proposed RL-PFC TV variant with additional degrees of freedom in the action space could not exploit additional degrees of freedom but still allocated them in a way such that the control goal could be achieved.

Further research will address training strategies that enable a greater generalization and investigate robustness against uncertainties, and noise. Moreover, more effort will be spent on investigating possibilities to exploit over actuation.

## 6 References

- [1] de Castro, R., Tanelli, M., Araujo, R., Savaresi, S.: Minimum-Time Path-Following for Highly Redundant Electric Vehicles. *IEEE Transactions on Control Systems Technology* 24 (2016) pp.487-501
- [2] Falcone, P., Tseng, H., Borrelli, F., Asgari, J., Hrovat, D.: MPC-based yaw and lateral stabilisation via active front steering and braking. *Vehicle System Dynamics* 46 (2008) pp.611-628
- [3] Lapierre, L., Soetanto, D., Pascoal, A.: Nonsingular path following control of a unicycle in the presence of parametric modelling uncertainties. *International Journal of Robust and Nonlinear Control* 16 (2006) pp.485-503
- [4] Raffo, G., Gomes, G., Normey-Rico, J., Kelber, C., Becker, L.: A Predictive Controller for Autonomous Vehicle Path Tracking. *IEEE Transactions on Intelligent Transportation Systems* 10 (2009) pp.92-102
- [5] Ritzer, P., Winter, C., Brembeck, J.: Experimental validation of geometric path following control with demand supervision on an over-actuated robotic vehicle. *IEEE Intelligent Vehicles Symposium (IV)* (2016) pp.539-545
- [6] Brembeck, J.: Model Based Energy Management and State Estimation for the Robotic Electric Vehicle ROboMObil. Dissertation, Technische Universität München, München (2018)
- [7] Duan, Y., Chen, X., Houthooft, R., Schulman, J., Abbeel, P.: Benchmarking Deep Reinforcement Learning for Continuous Control. *Proceedings of the 33rd International Conference on Machine Learning (ICML)* (2016) pp.1329-1338
- [8] Koch, W., Mancuso, R., West, R., Bestavros, A.: Reinforcement Learning for UAV Attitude Control. *ACM Transactions on Cyber-Physical Systems* 3 (2019) pp.1-21
- [9] Martinsen, A., Lekkas, A.: Straight-Path Following for Underactuated Marine Vessels using Deep Reinforcement Learning. *IFAC-PapersOnLine* 51 (2018) pp.329-334 11th IFAC Conference on Control Applications in Marine Systems, Robotics, and Vehicles (CAMS).
- [10] Kendall, A., Hawke, J., Janz, D., Mazur, P., Reda, D., Allen, J.-M., Lam, V.-D., Bewley, A., Shah, A.: Learning to Drive in a Day. *arXiv eprint arXiv:1807.00412* (2018)
- [11] Ritzer, P., Winter, C., Brembeck, J.: Advanced path following control of an overactuated robotic vehicle. *IEEE Intelligent Vehicles Symposium (IV)* (2015) pp.1120-1125

- [12] Modelica Association: Functional Mockup Interface. (Accessed May 2019) Available at: <https://www.fmi-standard.org/>
- [13] Brembeck, J., Ho, L., Schaub, A., Satzger, C., Hirzinger, G.: ROMO - The robotic electric Vehicle. 22nd IAVSD International Symposium on Dynamics of Vehicles on Roads and Tracks (2011)
- [14] Zimmer, D.: A Planar Mechanical Library for Teaching Modelica. Proceedings of the 9th International MODELICA Conference (2012) pp.681-690
- [15] Zimmer, D., Otter, M.: Real-time models for wheels and tyres in an object-oriented modelling framework. Vehicle System Dynamics 48 (2010) pp.189-216
- [16] Winter, C., Ritzer, P., Brembeck, J.: Experimental investigation of online path planning for electric vehicles. IEEE 19th International Conference on Intelligent Transportation Systems (ITSC) (2016) pp.1403-1409
- [17] Brembeck, J.: Nonlinear Constrained Moving Horizon Estimation Applied to Vehicle Position Estimation. Sensors (2019) Accepted for Publication.
- [18] Morin, P., Samson, C.: Motion Control of Wheeled Mobile Robots. In: Springer Handbook of Robotics. Springer Berlin Heidelberg (2008) pp.799-826
- [19] Sutton, R., Barto, A.: Reinforcement Learning: An Introduction 2nd edn. The MIT Press (2018)
- [20] Haarnoja, T., Zhou, A., Abbeel, P., Levine, S.: Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor. Proceedings of the 35th International Conference on Machine Learning (ICML) (2018) pp.1861-1870
- [21] Schulman, J., Wolski, F., Dhariwal, P., Radford, A., Klimov, O.: Proximal Policy Optimization Algorithms. arXiv eprint arXiv:1707.06347v2 (2017)
- [22] Lillicrap, T., Hunt, J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., Wierstra, D.: Continuous control with deep reinforcement learning. International Conference on Learning Representations (ICLR) (2016) arXiv eprint arXiv:1509.02971.
- [23] Ziebart, B.: Modeling Purposeful Adaptive Behavior with the Principle of Maximum Causal Entropy. Ph.D. dissertation, Carnegie Mellon University, Pittsburgh, USA (2010)
- [24] Haarnoja, T., Zhou, A., Hartikainen, K., Tucker, G., Ha, S., Tan, J., Kumar, V., Zhu, H., Gupta, A., Abbeel, P., Levine, S.: Soft Actor-Critic Algorithms and Applications. arXiv eprint arXiv:1812.05905 (2019)

- [25] Heißing, B., Ersoy, M., Gies, S.: *Fahrwerkhandbuch: Grundlagen, Fahrdynamik, Komponenten, Systeme, Mechatronik, Perspektiven* 4th edn. Springer Nature (2013)
- [26] Koch, W., Mancuso, R., Bestavros, A.: *Neuroflight: Next Generation Flight Control Firmware*. arXiv eprint arXiv:1901.06553 (2019)
- [27] Brockman, G., Cheung, V., Pettersson, L., Schneider, J., Schulman, J., Tang, J., Zaremba, W.: *OpenAI Gym*. (Accessed May 2019) Available at: <https://github.com/openai/gym>
- [28] Hill, A., Raffin, A., Ernestus, M., Gleave, A., Traore, R., Dhariwal, P., Hesse, C., Klimov, O., Nichol, A., Plappert, M., Radford, A., Schulman, J., Sidor, S., Wu, Y.: *Stable Baselines*. (Accessed May 2019) Available at: <https://github.com/hill-a/stable-baselines>
- [29] Brembeck, J., Ritzer, P.: *Energy optimal control of an over actuated Robotic Electric Vehicle using enhanced control allocation approaches*. IEEE Intelligent Vehicles Symposium (IV) (2012) pp.322-327

# A Simulation-Based Reinforcement Learning Approach for Long-Term Maneuver Planning in Highway Traffic Scenarios

**David Augustin M.Sc., Jeremias Schucker M.Sc.,  
Jeremy Tschirner B.Sc., Marius Hofmann B.Sc.,  
Opel Automobile GmbH, Rüsselsheim;  
Prof. Dr.-Ing. Ulrich Konigorski, Technische Universität Darmstadt**

## Abstract

Anticipatory planning and experience form the basis of human decision making in road traffic. Based on this principle, this paper presents an approach for making optimal high-level maneuver decisions for automated vehicles in highway scenarios by combining model-based and model-free methods of reinforcement learning. The model-based planning component performs forward simulation of the traffic scene and uses a heuristic reward function to derive lane change maneuver decisions. Its key component is a state transition model which predicts the future motion states of both the automated vehicle and its surrounding traffic participants while taking into account the mutual influence of neighboring vehicles. It comprises and combines Random Forest classification to estimate maneuver intentions for each traffic participant, prototypical trajectories as lateral motion primitives and potential fields for interaction-aware acceleration prediction for each vehicle in the scene. The task of the experience-based component is to set the target velocity of the automated vehicle. It is implemented as a variation of model-free Reinforcement Learning known as Q-learning. In order to support interpretability, the action-value function is approximated using a growing decision tree. The decision making module is integrated into a simulation framework that represents the agent's environment, provides different highway scenarios and manages traffic participants. A state-of-the-art trajectory planner realizes high-level maneuver requests of the decision module.

**Keywords** reinforcement learning, Q-learning, interaction-aware motion prediction, potential fields, prototypical trajectories, maneuver planning, behavior planning, automated driving.

## 1. INTRODUCTION AND RELATED WORK

Recently, the launch of highly automated to autonomous vehicles was repeatedly announced by various companies for the coming decade. A major challenge for maneuver planning in this context is the interaction with human drivers who predominate today's road traffic. Thus, both tactical maneuver decision making and trajectory planning need to assess the current traffic situation and its likely evolution. This is usually achieved by application of motion models that take into account the mutual influence of neighboring vehicles. These models are denoted as interaction-aware motion models.

## 1.1. RELATED WORK

Interaction-aware motion models, used in highway scenarios to predict the behavior of other road users, can be classified according to their scope. Motion models utilized for trajectory planning mostly focus on deterministic longitudinal motion prediction to describe vehicle following maneuvers and reactions to changing lead vehicles. A famous representative of this class is the Intelligent Driver Model [1]. Models that extend the scope to the prediction of lateral motion need to additionally estimate intentions for lane change. Gindele et al. model the decision making process as a hierarchical Dynamic Bayesian Network using vehicle-road and inter-vehicle relations to learn a policy model [2]. Action estimates are represented as conditional bivariate normal distributions which serve as inputs to a constant turn rate and acceleration model. Schulz et al. also model interaction-aware behavior prediction via a Dynamic Bayesian Network [3]. For each vehicle in the traffic scene all possible routes and all possible sequences are computed, in which conflict areas can be passed. Each resulting scenario is evaluated using a heuristic action model taking into account various influences that limit the permitted acceleration range. Wissing et al. apply intention-aware driver models in a Monte Carlo Simulation to predict future trajectories [4]. Probabilistic maneuver execution is modeled via Gaussian Processes. Bahram et al. combine an interaction-aware model used to simulate the risk-aware motion planning for each driver, and a Bayesian network classifier to determine the probability of different lateral motions [5]. Lavitzky et al. sample a set of trajectory primitives for each traffic participant [6]. For each individual trajectory, a collision probability is estimated which is used in a heuristic weighting function to update the probability of the trajectory under consideration. In order to assess future driving situations, planning-based concepts for behavior generation rely on interaction-aware motion models. The approaches of Brechtel et al. [7] and Ulbrich and Maurer [8] both formulate the driving task as a Partially Observable Markov Decision Process (POMDP). The former focuses on learning good representations of the continuous POMDP in specific situations employing a continuous POMDP solver. The latter simplifies the POMDP model using signal processing networks to calculate if performing a lane change maneuver is possible and beneficial. Bahram et al. [9] implement a hierarchical decision network to activate different behavioral strategies depending on the driving situation. Li et al. [10] propose a model-free Reinforcement Learning (RL) approach based on Q-learning to derive overtaking decisions in highway scenarios and compare its performance to manually designed decision rules.

## 1.2. PROPOSED APPROACH

Unlike the concepts presented in related work, our proposed approach combines model-based planning and model-free Q-learning to derive tactical maneuver decisions in highway scenarios. The idea follows human decision making which combines anticipatory planning and individual experience. The model-free component's ability to evaluate the current traffic scene may exceed the limited prediction horizon of the planning module. Thus, it forms a knowledge base which can be beneficial in complex maneuvers like

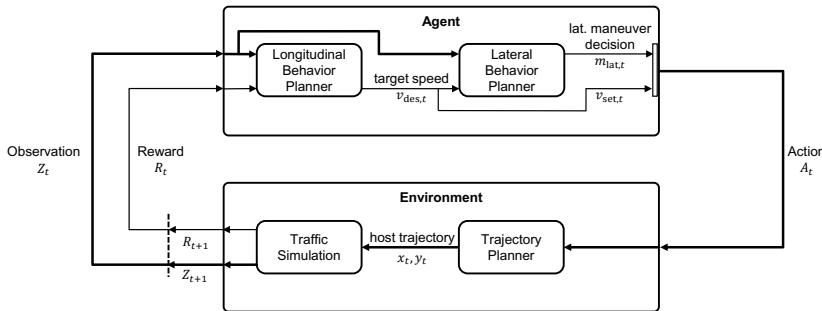


Figure 1: System overview of the presented Reinforcement Learning framework. The agent's functionality is divided into two parts, a model-free determination of the set speed and a model-based planning of lateral maneuver requests.

highway entries.

Figure 1 illustrates the proposed setup introducing the decision making module into an RL framework. In each RL setup it is distinguished between the agent, which receives state observations and a scalar reward and outputs a chosen action, and the environment, which executes the received action to produce a new state and new reward output in the following time step. In this context, the term action comprises a lateral maneuver decision and a set speed request. These requests are realized by a state-of-the-art trajectory planner which is embedded into the framework's environment. The static and dynamic driving situation is managed by a traffic simulator. The environment of the RL setup is described in more detail in Section 2. The agent's functionality is divided into two parts, a model-free target speed computation and a model-based planning of lateral change behavior. The former is implemented as a variation of Q-learning in which the state-action value function is approximated via a growing decision tree. The latter uses a heuristic reward function to assess several conflicting driving objectives within a limited planning horizon to derive lane change maneuver decisions. Therefore, it requires a state transition model to predict both, the automated vehicle's and the surrounding traffic participants' future motion states, while taking into account the mutual influence of neighboring vehicles. The model comprises and combines Random Forest classification to estimate maneuver intentions for each traffic participants, prototypical trajectories as lateral motion primitives and potential fields for interaction-aware acceleration prediction for each vehicle in the scene. The details of model-based and model-free behavior generation are discussed in Sections 3 and 4, respectively. After evaluation of the proposed methodology in Chapter 5, the paper concludes with an outlook on future work.

## 2. ENVIRONMENT

This chapter introduces all aspects of the agent's environment. Firstly, the RL problem is formalized as a POMDP, followed by a brief description of the applied simulation framework and the embedded trajectory planner.

### 2.1. PROBLEM FORMULATION

An environment for RL which is not fully observable i.e. there are hidden states which cannot directly be measured by the agent, can formally be described by a POMDP. This is a 7-tuple  $\{\mathcal{S}, \mathcal{A}, \mathcal{Z}, \mathcal{T}, \mathcal{O}, \mathcal{R}, \gamma\}$ , with  $\mathcal{S}$ ,  $\mathcal{A}$  and  $\mathcal{Z}$  denoting the state space, the action space, and the observation space, respectively. The function  $T(s', s, a) = \Pr(S_{t+1} = s' | S_t = s, A_t = a)$  represents the state transition probability to state  $s' \in \mathcal{S}$ , when choosing the action  $a \in \mathcal{A}$  in state  $s \in \mathcal{S}$ . The function  $\mathcal{O}(z', s', a) = \Pr(Z_{t+1} = z' | S_{t+1} = s', A_t = a)$  describes the probability of observation  $z' \in \mathcal{Z}$  in state  $s' \in \mathcal{S}$ , when action  $a \in \mathcal{A}$  was executed. The reward function  $\mathcal{R} = E(R_{t+1} | S_t = s, A_t = a)$  returns an immediate, scalar feedback for choosing action  $a \in \mathcal{A}$  in state  $s \in \mathcal{S}$ . The discount factor is denoted as  $\gamma$ .

In a traffic environment, the agent, which is referred to as 'host', shares the road with a total of  $N$  neighboring vehicles. The state vector  $s_i = [s_{m,i}, I_i]^T \in \mathcal{S}$  includes the motion state  $s_{m,i}$  and the intention  $I_i$  of the  $i$ -th neighboring vehicle  $V_i$ . The motion state  $s_{m,i} = [x_i, y_i, v_{x,i}, v_{y,i}, a_{x,i}, a_{y,i}]^T$  describes the vehicle's position, velocity and acceleration in a lane-relative coordinate system. The intentions  $I_i = [I_{\text{long},i}, I_{\text{lat},i}]$  include  $V_i$ 's desired velocity  $I_{\text{long},i} = v_{\text{des},i} \in \mathbb{R}$  and its lateral maneuver intention  $I_{\text{lat},i} \in [\text{LCL}, \text{LK}, \text{LCR}]$ . The lateral maneuver intention abbreviations represent Lane Change to the Left (LCL), Lane Keeping (LK), and Lane Change to the Right (LCR). The state vector of the host vehicle corresponds to its motion state  $s_{\text{host}} = s_{m,\text{host}}$ . The agent's intentions are determined by the behavior planning. Thus, the action space is defined as a discrete set  $\mathcal{A} = [a_{\text{long}}, a_{\text{lat}}] = [I_{\text{long}}, I_{\text{lat}}]_{\text{host}}$ . Possible lateral actions  $a_{\text{lat}} \in [\text{LCL}, \text{LK}, \text{LCR}]$  are lane changes to the left or right neighboring lane or remaining on the current lane. In longitudinal direction, the agent can vary the target speed in discrete steps of step size 10/3.6 m/s. From the agent's perspective both desired speed and maneuver intentions of traffic participants are hidden. Thus, the observation space  $\mathcal{Z}$  is limited to physically measurable quantities. It is assumed that the agent directly observes the lane-relative states  $z_i = [x_i, y_i, v_i]$  for each neighboring vehicle  $V_i$  and  $z_{\text{host}} = [y_{\text{host}}, v_{\text{host}}, a_{\text{host}}, \Delta x_{\text{LE}}]$  for itself, with  $x_i$  denoting the longitudinal distance of  $V_i$  relative to the agent,  $y_{(.)}$  representing the lateral offset from the lane center and  $v_{(.)}$  denoting the longitudinal velocity component. Regarding the host vehicle, the longitudinal acceleration  $a_{\text{host}}$  and the distance to the end of the driving lane  $\Delta x_{\text{LE}}$  are additionally observed. Thus, the joint state vector  $s \in \mathcal{S}$  and the joint observation vector  $z \in \mathcal{Z}$  are represented as  $s = [s_{\text{host}}, s_1, s_2, \dots, s_N]^T$  and  $z = [z_{\text{host}}, z_1, z_2, \dots, z_N]^T$ , respectively.

The state transition function results in:

$$\Pr(s'|s, a) = \Pr(s'_{\text{host}}|s_{\text{host}}, a_{\text{host}}) \prod_{i=1}^N \Pr(s'_i|s_i, I_i) \quad (1)$$

Observations are limited to a view range of 200 m. The observation function is modeled to be Gaussian distributed.

$$\Pr(z'_j|s'_j, a_j) \propto \mathcal{N}(z'_j|s'_j, \Sigma_{z,j}), \quad j \in \{\text{host}, 1, 2, \dots, N\} \quad (2)$$

The total reward is a linear combination of single rewards, assessing several conflicting driving objectives:

$$\mathcal{R}(s, a) = \sum_k \mu_k \mathcal{R}_k(s, a) \quad (3)$$

## 2.2. TRAFFIC SIMULATION

The key principle of RL methods is to learn from experience. Thus, the development of behavior planning based on RL techniques cannot be realized by driving on public roads, as experiencing dangerous situations is part of the learning process. Instead, a traffic simulation is required to provide and manage the stationary and dynamic traffic scene for algorithm development and testing. We apply SUMO, an open source microscopic traffic simulator [11], in combination with FLOW, an open source Python framework that integrates SUMO to support application of deep RL methods to traffic scenarios [12]. This framework allows us to easily define different road layouts, get access to various parameterizable driver models to control neighboring vehicles, and to randomly generate vehicles on the road. We apply the driver models 'Krauss' and 'SL2015' for longitudinal and lateral guidance, while varying their parameters with predefined probability distributions.

The key component of the lane change behavior planner is the interaction-aware motion prediction model, which is used for forward simulation of the traffic scene. The parametrization of the model is purely data driven and realized using supervised machine learning techniques. The required data is collected by simulating random traffic on a three-lane highway. For initial data generation, a rudimentary behavior planner is required that initiates lane change maneuver decisions of the host vehicle. This rudimentary behavior planner is realized via adaptation of the model-free RL approach, presented in Section 4, so that lateral maneuver decisions are performed.

The purpose of the model-free behavioral component is to make tactical maneuver decisions based on experience that may exceed the prediction horizon. In this paper we focus on applying this idea to highway entry maneuvers. A simulation scenario is created in which the rightmost driving lane is occupied. The agent must learn that an appropriate strategy for entering the highway can mean reducing the target speed while waiting for a gap to come up.

### 2.3. TRAJECTORY PLANNING

The trajectory planning module realizes the actions requested by the behavior model. We integrated the state-of-the-art trajectory planner presented by Schucker et al. [13], which uses a sampling-based approach to realize combined longitudinal and lateral trajectory planning. The interface between behavior and trajectory planning are lane change maneuver requests, the desired target velocity and a desired gap in case of a lane change.

## 3. LANE CHANGE BEHAVIOR PLANNING

The goal of behavior planning is to determine the driving policy of the automated vehicle that optimizes the common driving objective of all road users in the traffic scene. The common driving objective can be formulated as a reward function that takes into account current and future vehicle relations in order to evaluate various, possibly conflicting subgoals. This requires a model that allows predicting the evolution of the traffic scene, taking into account the interaction between neighboring vehicles. The automated vehicle affects traffic through its maneuver selection and the way maneuvers are executed. Determination of optimal maneuver execution is objective of trajectory planning, while behavior planning performs maneuver requests. In a structured highway environment all complex maneuvers, such as merging onto the highway, can be broken down into a sequence of basic maneuvers. These are Lane Keeping (LK), Lane Change to the Left (LCL), and Lane Change to the Right (LCR). Thus, the objective of behavior planning in highway scenarios is to find the optimal sequence of basic maneuvers (policy) that maximize the total expected reward within a limited prediction horizon.

---

#### Algorithm 1 Model-based Reinforcement Learning approach for lane change behavior planning

---

**Input:** Observation vector  $z$ , Prediction Horizons  $T_p$  and  $T_i$ , step width  $\Delta t$

```

1: Initialize motion state estimate  $s_{m,0} \leftarrow z$ 
2: for  $t \leftarrow [0 : \Delta t : T_p]$  do
3:    $Pr(I_{\text{lat},t}) \leftarrow \text{RANDOMFORESTCLASSIFIER}(s_{m,t})$   $\triangleright$  Estimate probabilities of lane change intentions
4:   priority_queue  $\leftarrow \text{COMPUTEPRIORITYQUEUE}(s_{m,t})$ 
5:   for vehicle  $v_i$ , maneuver  $m_{\kappa} := m_{i,k} \leftarrow \text{priority\_queue}$  do
6:      $\hat{y}_{\kappa,t:(t+T_i)} \leftarrow \text{PROTOTYPETRAJECTORIES}(s_{m,i,t})$   $\triangleright$  Get lateral motion primitives
7:      $[\hat{x}_{\kappa}, \hat{v}_{x,\kappa}, \hat{a}_{x,\kappa}]_{t:(t+T_i)} \leftarrow \text{CONSTANTACCELERATION}(s_{m,i,t})$   $\triangleright$  Get longitudinal motion primitives
8:      $S_{m,\kappa,t:(t+T_i)}, w_{\kappa,t} \leftarrow \text{POTENTIALFIELDS}([\hat{x}_{\kappa}, \hat{v}_{x,\kappa}, \hat{a}_{x,\kappa}]_{t:(t+T_i)})$   $\triangleright$  Estim. combined trajectory
9:     if  $v_i == v_{\text{host}}$  then
10:        $R_t(m_{\kappa,t}) \leftarrow \text{COMPUTEReward}(s_{t:(t+T_i)})$   $\triangleright$  Compute expected reward
11:     else
12:        $Pr(m_{\kappa,t}) \leftarrow w_{\kappa,t} Pr(I_{\kappa,t}) / \sum_{k \in [\text{LCL}, \text{LK}, \text{LCR}]} w_{i,k,t} Pr(I_{i,k,t})$   $\triangleright$  Estimate maneuver probabilities
13:     end if
14:   end for
15:    $s_{t+1} \leftarrow \text{UPDATEMOTIONSTATE}(s_{t:(t+T_i)}, Pr(m_{\kappa,t}))$   $\triangleright$  Update motion state estimate
16: end for
17:  $a_{\text{lat},t:(t+T_p)} \leftarrow \text{EVALUATEPOLICIES}(\mathcal{R}(m_{\text{host},t:(t+T_p)}))$   $\triangleright$  Select policy with maximum expected reward
Output: Action  $a_{\text{lat},t:(t+T_p)}$ 

```

---

Algorithm 1 describes the proposed algorithm for behavioral planning in pseudo code. The traffic scene is described by its state vector. Its first estimate corresponds to the observation vector. The traffic state is predicted iteratively for each time step  $t \in [0, T_p]$ . The discretization step width is defined as  $\Delta t = 0.25\text{s}$  and the prediction horizon is set to  $T_p = 10\text{s}$ . In each iteration, all hidden states, i.e. maneuver intentions of traffic participants, are estimated using a Random Forest classifier [14]. A priority queue is then defined, indicating the order in which the vehicles and their various maneuvers will be considered. In general, vehicles are considered from foremost to rearmost, while taking into account lane keeping maneuvers before lane change maneuvers. For each pair of vehicle  $V_i$  and maneuver  $m_{i,k}$  a set of lateral motion primitives is defined using prototypical lateral trajectories extracted from data. Longitudinal motion primitives are generated by sampling the longitudinal acceleration probability density function, which was estimated in the previous time step, and assuming constant acceleration within a horizon of  $T_i = 5\text{s}$ . All lateral and longitudinal motion primitives are combined and a weighting factor is computed for each combination by evaluating potential fields that take into account the desired speed  $v_{\text{des},i}$  of the vehicle  $V_i$  and the safety margins relative to surrounding traffic objects. The final trajectory  $s_{\kappa,t:(t+T_i)}$  is calculated as a weighted combination of all trajectory primitives and its weighting factor  $w_\kappa$  is computed utilizing the potential fields. The index  $\kappa$  is introduced as an abbreviation of the combination of vehicle index  $i$  and maneuver index  $k$ . For traffic participants the probability of maneuver execution  $\text{Pr}(m_\kappa)$  is calculated as the normalized product of intention estimation  $\text{Pr}(I_\kappa)$  and trajectory weighting factor  $w_\kappa$  by:

$$\text{Pr}(m_\kappa) = \frac{w_\kappa \text{Pr}(I_\kappa)}{\sum_{k \in [\text{LCL}, \text{LK}, \text{LCR}]} w_{i,k} \text{Pr}(I_{i,k})} \quad (4)$$

The intention estimation  $\text{Pr}(I_\kappa)$  expresses the driver's goal-oriented choice of maneuver, while the trajectory weighting factor  $w_\kappa$  evaluates its feasibility taking into account the surrounding traffic. When regarding the agent, the expected reward for the time horizon  $T_i$  is calculated instead:

$$\mathcal{R}_t = \mathcal{R}_{\text{vel},t} + \mathcal{R}_{\text{accel},t} + \mathcal{R}_{\text{RFG},t} + \mathcal{R}_{\text{POR},t} + \mathcal{R}_{\text{marg},t} + \mathcal{R}_{\text{crash},t} \quad (5)$$

$$\text{with } \mathcal{R}_{\text{vel},t} = \mu_{\text{vel}} \cdot \sum_{t=0}^{T_i} (v_{\text{des}} - ||v_{\text{des}} - v_{x,t}||), \quad (6)$$

$$\mathcal{R}_{\text{accel},t} = -\mu_{\text{accel}} \cdot N_{T_p} \cdot a_{x,t}^2, \quad (7)$$

$$\mathcal{R}_{\text{RFG},t} = \mu_{\text{LCR}} \cdot \mathbf{I}_{m_t}(\text{LCR}) - \mu_{\text{LCL}} \cdot \mathbf{I}_{m_t}(\text{LCL}), \quad (8)$$

$$\mathcal{R}_{\text{POR},t} = -\mu_{\text{POR}} \cdot \mathbf{I}_{\mathcal{S}}(\text{POR}), \quad (9)$$

$$\mathcal{R}_{\text{marg},t} = -\mu_{\text{marg}} \cdot (1 - w_{\kappa,t}), \quad (10)$$

$$\mathcal{R}_{\text{crash},t} = -\mu_{\text{crash}} \cdot \mathbf{I}_{\mathcal{S}}(\text{crash}). \quad (11)$$

The reward function assesses goal- ( $\mathcal{R}_{\text{vel},t}$ ), comfort- ( $\mathcal{R}_{\text{accel},t}$ ), traffic-rule- ( $\mathcal{R}_{\text{RFG},t}$ ,  $\mathcal{R}_{\text{POR},t}$ ) and safety-oriented ( $\mathcal{R}_{\text{margin},t}$ ,  $\mathcal{R}_{\text{crash},t}$ ) driving objectives. The acronym RFG denotes the German traffic rule "Rechtsfahrgebot", whereas POR expresses the prohibition to overtake traffic participants on their right

side. Each individual reward term has a weighting parameter  $\mu_{(.)}$ . The parameter definition ensures that safety-critical conditions are punished much more severely than any safe driving situation. In each time step  $t$  the expected reward is calculated for all maneuvers of the host vehicle. When the priority queue is empty, the traffic state  $s_{t+1}$  is estimated by evaluating the trajectory predictions at time  $t + \Delta t$  that correspond to maneuvers with the highest estimated probability for each vehicle in the traffic scene. For the automated vehicle the lane keeping trajectory is evaluated.

When the traffic scene prediction for the whole prediction horizon  $T_p$  is completed, the calculated rewards are analyzed in order to find time periods in which the expected reward for a lane change exceed the expected reward for the lane keeping maneuver. These intervals are examined to determine the point in time  $t_{LC}$  when a lane change initiation is most beneficial. The approximately optimal policy is determined by selecting up to  $t = t_{LC}$  lane keeping maneuvers in each successive time step and then selecting lane changing maneuvers as lateral action requests. Starting from time  $t = t_{LC}$ , the traffic scene prediction is recalculated. In the following, selected components of the presented algorithm are described in more detail.

### 3.1. INTENTION ESTIMATION VIA RANDOM FOREST CLASSIFICATION

The maneuver intentions of each traffic participant  $V_i$  are estimated iteratively in each time step based on the feature vector  $\mathcal{X}_i = [y_i, v_{y,i}, \text{TG}_{\text{FC},i}, \Delta v_{\text{FC},i}]$ . The features  $y_i$  and  $v_{y,i}$  are the lane-relative lateral offset and the lateral velocity of vehicle  $V_i$ . Time gap  $\text{TG}_{\text{FC},i}$  and relative velocity  $\Delta v_{\text{FC},i}$  characterize the relation of vehicle  $V_i$  and its leading vehicle (with FC abbreviating Front Center). For classification, we apply an implementation of the Random Forest classifier, which outputs class probabilities [14]. Random Forest classifiers are based on an ensemble of decision trees. They inherently support multi-class classification and they can handle unobserved features.

A crucial part of all classification problems is labeling the data set. We applied and extended the automated labeling approach presented in [15]. Lane change maneuvers are labeled by searching the data set for points in time at which lane markings are crossed. In their surrounding intervals the course of lateral motion is analyzed to determine the start point and end point of each maneuver. Based on the safety margin potential fields presented in 3.3, we examine if the lane change maneuver could have been initiated earlier or if it was inhibited by neighboring vehicles. For consecutive time steps in which the lane change maneuver was inhibited before maneuver execution started, the lane change intention is labeled. These class labels are taken into account while training the classifier.

### 3.2. LATERAL MOTION PRIMITIVES BASED ON PROTOTYPE TRAJECTORIES

Lateral motion primitives are extracted from prototypical lane change trajectories. These prototype trajectories are generated from data by aggregating similar lane change courses using the k-Means clustering algorithm and representing each cluster by a 5th order polynomial. This approach is presented in [15].

Here, we chose the k-Means algorithm over the Agglomerative Hierarchical Clustering algorithm, which achieved the best results in [15], because k-Means support iterative learning of prototype clusters. In each new learning iteration, the cluster representative calculated in the previous iteration can be utilized as initialization.

For lane change maneuvers, one lateral motion primitive  $\hat{y}_{K,i}$  is extracted from each prototypical lane change trajectory  $y_{proto,i}$  by:

$$\hat{y}_{K,i}(t) = y_{proto,i}(t + t_{0,i}) \quad , \quad t \in [0, T_i] \quad (12)$$

$$\text{s.t.} \quad y_{proto,i}(t_{0,i}) = y_{i,t} \quad (13)$$

with  $y_{i,t}$  denoting the lateral offset of vehicle  $i$  at time  $t$ . For all values of  $t$  that lie outside the definition limits of the prototype trajectory the last value of the trajectory is held. When evaluating lane keeping maneuvers, all prototypes for LCL- and LCR-maneuvers are shifted to generate prototypical lateral courses that lead the vehicle to the center of its lane and only a single lateral motion primitive is calculated.

### 3.3. ESTIMATION OF COMBINED TRAJECTORIES UTILIZING POTENTIAL FIELDS

We assume that driving consistently and with foresight are goals for both human drivers and the trajectory planner. Following this assumption, we model the longitudinal motion of each vehicle  $V_i$  within the horizon  $T_i = 5$  s via constant acceleration. This model is only valid if the acceleration value  $a_{i,t}$  is selected based on the acceleration in the previous time step  $a_{i,t-1}$ , as well as the desired velocity  $v_{des,i}$ , and the predicted trajectories of neighboring vehicles  $s_{nv,t:(t+T_i)}$ . By this it is ensured that safety clearances are maintained. Initially, a set for  $N_a$  acceleration values  $\hat{a}$  is sampled equidistantly from the acceleration probability density function  $\mathcal{N}(a_{i,t-1}, \sigma_{i,t-1}^2)$ , which is estimated in the previous time step. Longitudinal motion primitives are calculated for each sample utilizing a constant acceleration model. Each primitive is initially weighted by:

$$w_0(\hat{a}_k) = \mathcal{N}(\hat{a}_k | a_{i,t-1}, \sigma_{i,t-1}^2) \quad (14)$$

in order to promote consistency in longitudinal acceleration.

A second potential  $w_v(\hat{a}_k)$  favors trajectory primitives approaching the desired velocity:

$$w_v(\hat{a}_k) = \frac{v_{des,i} - ||v_{des,i} - (T_i \cdot \hat{a}_k + v_{i,0})||}{v_{des,i}}. \quad (15)$$

The desired velocity  $v_{des,i}$  of vehicle  $V_i$  is estimated as the maximum of all observed velocity values of that vehicle (assuming the speed limit is unchanged). Regarding the host vehicle, the desired velocity is selected by the model-free component.

In order to ensure compliance with the safety clearances, potential fields are generated that assign a weight to each point of the trajectory according to its time gap and its speed difference to all relevant neighboring vehicles. Relevant vehicles are the leading vehicle on the current lane and the leading and

following vehicles on the target lane during lane change maneuvers. The generation of these potential fields, denoted as Safety Margin Potential (SMP) fields, is purely data driven. For each pair of maneuver type and relevant vehicle, a matrix is created that subdivides the time gap domain and the relative velocity domain into discretized intervals. Each element of the matrix is initialized by one to ensure no weight ever becomes zero. All coherent maneuvers in a training data set are examined to determine their most safety-critical state. For each determined safety-critical state, all elements of the matrix that represent states of less or equal criticality are increased by one. Finally, the matrices are normalized so that the weight becomes one for all non-critical states. Thus, each element in the matrix corresponds to the percentage of drivers accepting the represented pair of time gap and relative velocity. The weighting factor  $w_{\text{SMP}}(\hat{s}_{i,k,t:(t+T_i)}, s_{\text{nv},t:(t+T_i)})$  for a combined trajectory primitive is calculated by evaluating the safety margin potential fields for its most safety-critical state.

Thus, the acceleration mean  $a_{i,t}$  of the combined trajectory can be calculated by:

$$a_{i,t} = c_a \frac{\sum_{k=1}^{N_a} w_0(\hat{a}_k) \cdot w_v(\hat{a}_k) \cdot w_{\text{SMP}}(\hat{s}_{i,k,t:(t+T_i)}, s_{\text{nv},t:(t+T_i)}) \cdot \hat{a}_k}{\sum_{k=1}^{N_a} w_0(\hat{a}_k) \cdot w_v(\hat{a}_k) \cdot w_{\text{SMP}}(\hat{s}_{i,k,t:(t+T_i)}, s_{\text{nv},t:(t+T_i)})} \quad (16)$$

with  $s_{\text{nv},t:(t+T_i)}$  and  $\hat{s}_{i,k,t:(t+T_i)}$  representing the predicted trajectories of relevant neighboring vehicles and the set of combined trajectory primitives for vehicle  $i$ , respectively. The constant factor  $c_a$  is used to represent the willingness of drivers to change acceleration. The variance of acceleration estimation is calculated via:

$$\sigma_{i,t}^2 = \frac{\sum_{k=1}^{N_a} w_0(\hat{a}_k) \cdot w_v(\hat{a}_k) \cdot w_{\text{SMP}}(\hat{s}_{i,k,t:(t+T_i)}, s_{\text{mv},t:(t+T_i)}) \cdot (\hat{a}_k - a_{i,t})^2}{\sum_{k=1}^{N_a} w_0(\hat{a}_k) \cdot w_v(\hat{a}_k) \cdot w_{\text{SMP}}(\hat{s}_{i,k,t:(t+T_i)}, s_{\text{mv},t:(t+T_i)})} \quad (17)$$

#### 4. MODEL-FREE TARGET SPEED CALCULATION

Imitating the human ability to make decisions based on past experience is the main purpose of using model-free Q-learning to calculate the target speed. In Q-learning the optimal policy, i.e. the mapping from states to actions that maximize the total received reward, is selected based on an action-value function  $Q(s,a)$ . The action-value function is defined as the sum of all rewards received after starting in state  $s$  and choosing action  $a$  until a terminal state is reached. It can be approximated by any general function approximator. We chose to apply a growing decision tree for this task, following Pyeatt's approach presented in [16]. The main reason for our choice of the function approximator is the superior interpretability of decision trees when compared to neuronal networks.

Initially, the decision tree consists of a single leaf node representing the entire state space. During runtime, both the observation input and the changes of the action-value function are gathered and stored in a buffer. For each time step  $t$ , the change of the previous action-value function is computed as:

$$\Delta Q(s_{t-1}, a_{t-1}) = \alpha [R_t + \gamma \max_{a_t} (Q(s_t, a_t)) - Q(s_{t-1}, a_{t-1})] \quad (18)$$

with  $\alpha$  denoting the learning rate. When the collected data exceed a minimum threshold, it is tested if the leaf node should be split (see Algorithm 2). The decision boundary is calculated by evaluating the T-statistic for each input variable and choosing the variable with the highest T-statistic as the decision variable. The leaf node is replaced by a decision node and two new leaf nodes are added. Thus, a growing decision tree is formed, which allows the state space to be divided with varying levels of resolution. A more detailed description of the algorithm is provided by Pyeatt and Howe [16].

---

**Algorithm 2** Q-learning using decision tree for function approximation [16]

**Input:** Observation  $z_t$ , Reward  $r_t$

```

1:  $s_t \leftarrow \text{FINDLEAFNODE}(z_t)$ 
2:  $a_{\text{long},t} \leftarrow \text{SELECTACTION}(s_t, Q(s_t, a))$ 
3:  $[Q(s_{t-1}, a_{t-1}), \Delta Q(s_{t-1}, a_{t-1})] \leftarrow \text{UPDATEACTIONVALUEFUNCTION}(r_t, Q(s_{t-1}, a_{t-1}))$ 
4: History  $\leftarrow \text{AddToHistoryBuffer}(\Delta Q(s_{t-1}, a_{t-1}), z_t)$ 
5: if History > min_length then
6:    $[\mu, \sigma] \leftarrow \text{CALULATEPARAMETERS}(\text{History.} \Delta Q(s_{t-1}, a_{t-1}))$   $\triangleright$  Compute mean and std. deviation
7:   if  $\mu < 2\sigma$  then  $\triangleright$  Split Leaf Node
8:      $D \leftarrow \text{SELECTDECISIONBOUDARY(HISTORY)}$   $\triangleright$  Based on T-statistic
9:   end if
10: end if
Output: Action  $a_{\text{long},t}$ 

```

Long, et al.

## 4.1. APPLICATION: ENTERING THE HIGHWAY

The presented Q-learning method is utilized to derive the target speed of the host vehicle while driving on the highway access ramp. It receives the observation state  $z$  as input. We facilitate the learning process by structuring  $z$  so that neighboring vehicles are arranged per lane. The action space is equally discretized within the interval  $a_{\text{long}} \in [0, v_{\text{max}}]$ . The upper bound of the target velocity is limited by the traffic rules. Step size is set to 10/3.6 m/s. The reward function integrated into the environment is defined as:

$$\mathcal{R}_{\text{long}} = \mathcal{R}_{\text{long,vel}} + \mathcal{R}_{\text{long,act}} + \mathcal{R}_{\text{long,marg}} + \mathcal{R}_{\text{long,crash}} \quad (19)$$

$$\text{with } \mathcal{R}_{\text{long,vel}} = -\mu_{\text{long,vel}} \frac{v_{\text{max}} - ||v_{\text{max}} - v_{\text{host}}||}{v_{\text{max}}}, \quad (20)$$

$$\mathcal{R}_{\text{long,act}} = -\mu_{\text{long,act}} \cdot \mathbf{I}_A(a_{\text{long},t} \neq a_{\text{long},t-1}), \quad (21)$$

$$\mathcal{R}_{\text{long,marg}} = \begin{cases} -\mu_{\text{long,marg}} \frac{\text{TG}_{\text{thres}} - \text{TG}_{\text{FC}}}{\text{TG}_{\text{thres}}} & , \text{TG}_{\text{FC}} < \text{TG}_{\text{thres}} \\ 0 & , \text{otherwise} \end{cases} \quad (22)$$

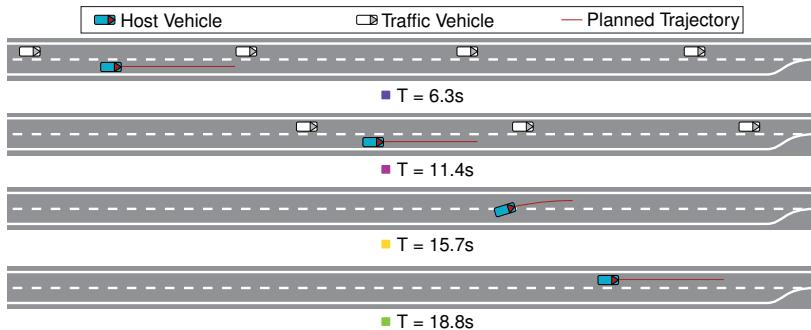
$$\mathcal{R}_{\text{long,crash}} = -\mu_{\text{long,crash}} \cdot \mathbf{I}_S(\text{crash}). \quad (23)$$

The total reward combines individual rewards to assess driving speed  $\mathcal{R}_{\text{long,vel}}$ , changes of the action state  $\mathcal{R}_{\text{long,act}}$ , violation of safety margins  $\mathcal{R}_{\text{long,marg}}$  and the occurrence of accidents  $\mathcal{R}_{\text{long,crash}}$ . The Factors  $\mu$  are weighting parameters. The variables  $\text{TG}_{\text{FC}}$  and  $\text{TG}_{\text{thres}}$  denote the time gap of the host vehicle relative to its lead vehicle and a threshold, respectively. Indicator functions are denoted as  $\mathbf{I}(\cdot)$ .

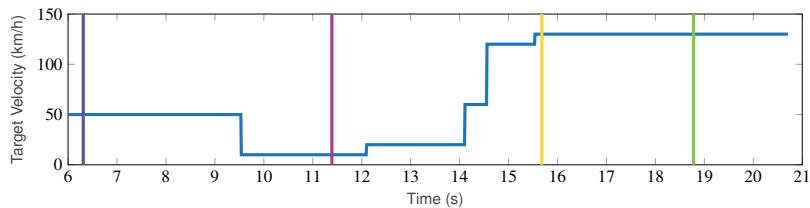
## 5. EVALUATION

In a first qualitative evaluation of the model-free driving strategy component, a highway access scenario is considered in which the target lane is blocked by dense traffic of fast-moving road users. The traffic scene is designed such that it is impossible for the host vehicle to merge onto the highway before all other vehicles have passed. Previously, the decision tree was trained in 500 simulation runs with randomized traffic on the target lane. Both, existence and velocity of up to seven road users were selected randomly. After the training phase the decision tree divides the state space into 152 leaf nodes.

Figure 2a shows the evaluation scenario for different points in time. In Figure 2b the calculated lateral actions are plotted over time. The course of the action requests shows that the decision tree was able to learn a tactical behavior. At the beginning, the requested target speed is reduced. Starting from time  $t = 12$  s the desired velocity is iteratively increased. At  $t = 15.7$  s the host vehicle successfully merges onto the driving lane.



(a) The traffic scene is displayed for various points in time.



(b) The calculated target velocities are plotted over time. Each time point corresponding to a driving scenario displayed in Figure 2a is marked by a colored vertical line.

Figure 2: Qualitative evaluation of the model-free RL component in a highway access scenario.

## 6. CONCLUSION AND FUTURE WORK

In this paper an approach for behavior planning in highway scenarios is presented that combines model-free and model-based RL methods. The target speed is determined by the model-free component which is implemented as a variation of Q-learning using a growing decision tree to approximate the action-value function. The planning-based component determines an approximately optimal sequence of lateral maneuver requests by assessing the current driving scene and its likely evolution. The main contributions of this paper are:

- a novel approach of combined model-free and model-based RL for behavior generation, and
- an innovative modular concept for interaction-aware motion prediction in which all modules except of the Random Forest classifier, utilized for maneuver intention estimation, are easy to interpret and the parametrization is purely data-driven.

First tests have shown a fast computation time and the general functionality for the model-free and for the model-based component. A detailed quantitative evaluation of all modules presented is still required and will be the focus of our future work.

## REFERENCES

- [1] Martin Treiber, Ansgar Hennecke, and Dirk Helbing. Congested traffic states in empirical observations and microscopic simulations. *Physical review E*, 62(2):1805, 2000.
- [2] Tobias Gindele, Sebastian Brechtel, and Rudiger Dillmann. Learning driver behavior models from traffic observations for decision making and planning. *IEEE Intelligent Transportation Systems Magazine*, 7(1):69–79, 2015.
- [3] Jens Schulz, Constantin Hubmann, Julian Löchner, and Darius Burschka. Interaction-aware probabilistic behavior prediction in urban environments. In *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3999–4006. IEEE, 2018.
- [4] Christian Wissing, Till Nattermann, Karl-Heinz Glander, and Torsten Bertram. Interaction-aware long-term driving situation prediction. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 137–143. IEEE, 2018.
- [5] Mohammad Bahram, Constantin Hubmann, Andreas Lawitzky, Michael Aeberhard, and Dirk Wollherr. A combined model- and learning-based framework for interaction-aware maneuver prediction. *IEEE Transactions on Intelligent Transportation Systems*, 17(6):1538–1550, 2016.
- [6] Andreas Lawitzky, Daniel Althoff, Christoph F Passenberg, Georg Tanzmeister, Dirk Wollherr, and Martin Buss. Interactive scene prediction for automotive applications. In *2013 IEEE Intelligent Vehicles Symposium (IV)*, pages 1028–1033. IEEE, 2013.

- [7] Sebastian Brechtel, Tobias Gindele, and Rüdiger Dillmann. Probabilistic decision-making under uncertainty for autonomous driving using continuous POMDPs. In *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pages 392–399. IEEE, 2014.
- [8] Simon Ulbrich and Markus Maurer. Probabilistic online POMDP decision making for lane changes in fully automated driving. In *16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*, pages 2063–2067. IEEE, 2013.
- [9] Mohammad Bahram, Anton Wolf, Michael Aeberhard, and Dirk Wollherr. A prediction-based reactive driving strategy for highly automated driving function on freeways. In *2014 IEEE Intelligent Vehicles Symposium Proceedings*, pages 400–406. IEEE, 2014.
- [10] Xin Li, Xin Xu, and Lei Zuo. Reinforcement learning based overtaking decision-making for highway autonomous driving. In *2015 Sixth International Conference on Intelligent Control and Information Processing (ICICIP)*, pages 336–342. IEEE, 2015.
- [11] Pablo Alvarez Lopez, Michael Behrisch, Laura Bieker-Walz, Jakob Erdmann, Yun-Pang Flötteröd, Robert Hilbrich, Leonhard Lücken, Johannes Rummel, Peter Wagner, and Evamarie Wießner. Microscopic traffic simulation using SUMO. In *The 21st IEEE International Conference on Intelligent Transportation Systems*. IEEE, 2018.
- [12] Nishant Kheterpal, Kanaad Parvate, Cathy Wu, Aboudy Kreidieh, Eugene Vinitsky, and Alexandre Bayen. Flow: Deep reinforcement learning for control in sumo. *SUMO*, pages 134–151, 2018.
- [13] Jeremias Schucker, Tobias Kohlmann, and Ulrich Konigorski. A complete concept for combined longitudinal and lateral trajectory planning for automated driving on highways. In *AUTOREG 2019: Regelungstechnik für autonomes Fahren und vernetzte Mobilität*, 2019.
- [14] Leo Breiman. Random forests. *Machine learning*, 45(1):5–32, 2001.
- [15] David Augustin, Marius Hofmann, and Ulrich Konigorski. Motion pattern recognition for maneuver detection and trajectory prediction on highways. In *2018 IEEE International Conference on Vehicular Electronics and Safety (ICVES)*, pages 1–8. IEEE, 2018.
- [16] Larry D Pyeatt and Adele E Howe. Decision tree function approximation in reinforcement learning. In *Proceedings of the third international symposium on adaptive systems: evolutionary computation and probabilistic graphical models*, volume 2, pages 70–77. Cuba, 2001.

# Fahrzeugdetektion mit stationären Kameras zur automatischen Verkehrsüberwachung

**M. Oeljeklaus, N. Stannartz, M. Schmidt,**

apl. Prof. Dr. rer. nat. **F. Hoffmann,**

Univ.-Prof. Dr.-Ing. Prof. h.c. Dr. h.c. **T. Bertram,**

Lehrstuhl für Regelungssystemtechnik, Technische Universität Dortmund

## Kurzfassung

Menschliche Fahrfehler stellen die Hauptursache für Unfälle im Straßenverkehr dar. Die automatische Verkehrsüberwachung bietet einen Beitrag, um die Vision des unfallfreien Straßenverkehrs zu erreichen. Eine solche Infrastruktur erhöht unmittelbar die Verkehrssicherheit insbesondere vor dem Hintergrund einer langwierigen Durchdringung des Fahrzeugbestandes durch neue Assistenzsysteme. Das Multi Funktionale Detektions System (siehe Bild 1) erkennt an Autobahnabfahrten sowie Park- und Rastanlagen potenzielle Falschfahrer bei der Auffahrt auf die falsche Richtungsfahrbahn. Typischerweise werden dabei ortsfeste Messplattformen eingesetzt, hierfür bieten Kamerasensoren besonders günstige Voraussetzungen. Der vorliegende Beitrag betrachtet die Fahrzeugdetektion in Kamerabildern für die Integration in ein Falschfahrerwarnsystem. Für diese Anwendung ist die Realisierung von möglichst schnellen Verarbeitungszeiten entscheidend. Gängige Methoden der kamerabasierten Objektdetektion führen zu diesem Zweck eine vollständige Abtastung des aufgezeichneten Bildes durch. Aufgrund der feststehenden Kameraposition und der bekannten statischen Verkehrselemente lässt sich jedoch der Suchraum deutlich einschränken. Der Ansatz basiert auf einer reduzierten Suchstrategie, welche die vorteilhaften Eigenschaften herkömmlicher Verfahren zur Objektdetektion erhält.

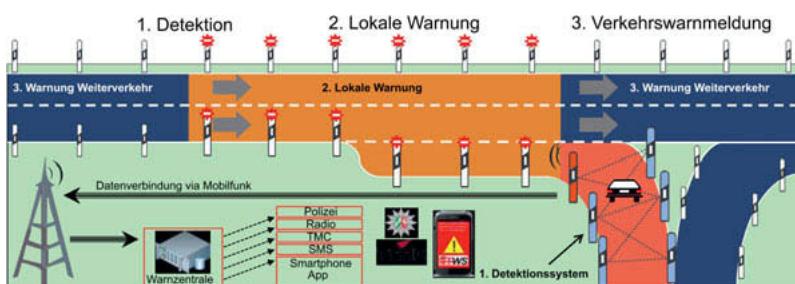


Bild 1: Systemarchitektur des Multi Funktionalen Detektions Systems [1].

## 1. Einleitung

Der Anteil von Unfällen im Straßenverkehr, bei denen menschliche Fahrfehler die Hauptursache darstellen, wird laut [22] auf über 90% beziffert. Um die Vision des unfallfreien Straßenverkehrs umzusetzen, bietet die automatische Verkehrsüberwachung einen Beitrag für Assistenzsysteme, welche unabhängig von einer langwierigen Durchdringung des Fahrzeugbestandes sind und deren Installation von zentraler Stelle durch die Straßenbauverwaltung erfolgt. Beispielsweise wird das Multi Funktionale Detektions System (MFDS) [1] eingesetzt, um an Autobahnabfahrten sowie Park- und Rastanlagen potenzielle Falschfahrer bei der Auffahrt auf die falsche Richtungsfahrbahn zu erkennen (siehe Bild 1). Falschfahrer werden durch Leuchtsignale gewarnt, weiterhin wird die Gefahreninformation über eine Datenverbindung an die Verkehrsleitstelle gemeldet. Allgemein stellt die präzise und echtzeitnahe Messung des Verkehrsflusses und weiterer verkehrsbezogener Kenngrößen ein Schlüsselement für intelligente Verkehrsleitsysteme dar.

Aus technischer Sicht bieten Kamerasensoren gute Voraussetzungen für die automatische Verkehrsüberwachung, da die visuelle Erscheinung einer Verkehrsszene praktisch alle relevanten Informationen über die in ihr enthaltenen Fahrzeuge beinhaltet. Die sensorische Erfassung der Verkehrsszene erfolgt dabei von einem ortsfesten Messsystem. Für die Verkehrsüberwachung sind insbesondere die Positionen und Bewegungen der Verkehrsteilnehmer relevant. Der Straßenverlauf und Verkehrselemente wie die Beschilderung hingegen verändern sich nicht, beziehungsweise nur bei weniger häufigen, aber bekannten Sonderereignissen wie etwa Baustellen und lassen sich somit als Vorwissen berücksichtigen. Der vorliegende Beitrag fokussiert sich auf die Detektion von Verkehrsteilnehmern in Kamerabildern und betrachtet hierzu exemplarisch die Fahrzeugdetektion zur Integration in das Falschfahrerwarnsystem MFDS [1].

Für die angestrebte Anwendung sind kurze Verarbeitungszeiten eine Voraussetzung. So muss die Warnung einen potentiellen Falschfahrer unverzüglich, insbesondere noch vor dem Befahren der Autobahn in entgegengesetzter Richtung, erreichen. Allgemein ist die Verfügbarkeit von zeitaktuellen Informationen für die Verkehrsleittechnik von hoher Bedeutung. Gängige Methoden für die kamerabasierte Objektdetektion lassen sich in die Verarbeitungsschritte der Bildabtastung und die eigentliche Klassifikation der Objekte untergliedern. Algorithmisch wird dabei für jede Abtastung eine Klassifikation des abgetasteten Bildausschnitts durchgeführt. Zur Realisierung schneller Rechenzeiten lassen sich prinzipiell für beide Verarbeitungsschritte Vereinfachungen durchführen. Die im Klassifikationsschritt erreichbare Detektionsgüte wird jedoch direkt durch die Reduktion der Modellkapazität beeinflusst. Bei der Bildabtastung ergibt sich hingegen die Möglichkeit, den Suchraum aufgrund der festste-

henden Kameraposition und der bekannten statischen Verkehrselemente einzuschränken ohne die Detektionsgüte wesentlich zu beeinträchtigen. Für die betrachteten Szenen an Autobahnab- und Rastplatzzufahrten ergibt sich anschaulich, dass die gesuchten Fahrzeuge insbesondere dort auftreten, wo Bewegungen im Umfeld rasche zeitliche Änderungen des Kamerabildes hervorrufen. Um solche zeitliche Veränderungen im Kamerabild zu verorten, lassen sich bekannte Methoden zur Hintergrundsubtraktion anwenden [28]. Da Veränderungen im Kamerabild jedoch auch aufgrund von Umwelteinflüssen entstehen können, folgt hieraus noch kein hinreichendes Kriterium für das Vorhandensein eines Fahrzeugs. Somit ergeben sich zunächst nur Objekthypothesen für vorhandene Fahrzeuge, welche der weiteren Verarbeitung im Klassifikationsschritt zugeführt werden.

Für die Klassifikation von Bildern und Bildausschnitten bilden Convolutional Neural Networks (CNN) [10] den derzeitigen Stand der Technik. CNNs verwenden eine Reihe hierarchischer Modellschichten, um den Prozess des maschinellen Lernens durchzuführen. Dabei werden in den einzelnen Hierarchieebenen statistische Merkmale mit steigendem Abstraktionsgrad ausgeprägt, bis am Modellausgang die gewünschte Zielgröße, etwa eine Beschreibung der detektierten Objekte, entsteht. Gängige CNN Architekturen zur Objektdetektion, wie etwa der Faster R-CNN [19] Ansatz (siehe Bild 3), weisen einige Besonderheiten auf, welche sich für die Objektdetektion als vorteilhaft erwiesen haben. So muss etwa davon ausgegangen werden, dass die Bestimmung der Objekthypothesen fehlerbehaftet ist. Dies betrifft nicht nur die eigentliche Existenz, sondern auch die Lokalisierung der Objekte im Bild. Eine fehlerhafte Lokalisierung kann durch eine Regression des relativen Versatzes zwischen Objekthypothese und tatsächlicher Objektposition korrigiert werden, was durch die Erweiterung der eigentlichen Objektklassifikation um zusätzliche Ausgangsgrößen zur Beschreibung des Versatzes realisiert wird. Weiterhin werden einmal berechnete Merkmale für die Detektion mehrerer Objekte im Bild verwendet, so dass eine aufwändige Neuberechnung pro Objekt entfallen kann. Jedoch sind die eingesetzten Suchstrategien zur vollständigen Abtastung des zu verarbeitenden Bildes in der betrachteten Anwendung von Nachteil, da aufgrund der statischen Kameraposition und dem vorhandenen Vorwissen bereits eine deutliche Eingrenzung der Objekthypothesen erfolgen kann. In der vorliegenden Arbeit wird daher eine CNN Architektur entworfen, welche eine reduzierte Suchstrategie realisiert und dabei die beschriebenen vorteilhaften Eigenschaften erhalten kann.

## 2. Verwandte Arbeiten

Die Objekterkennung in digitalen Bildern hat in den vergangenen Jahren einen grundlegenden Wandel erfahren. Ein wesentlicher Beitrag aus dem Jahre 2001 ist das als Viola-Jones-

Methode [29] bekannt gewordene Verfahren, welches ursprünglich zur Gesichtserkennung eingesetzt wurde. Dieses zeichnet sich durch hohe Genauigkeiten und insbesondere durch eine schnelle Berechnung im Verhältnis zu den Rechenkapazitäten der damaligen Zeit aus. Im Wesentlichen besteht die Viola-Jones-Methode aus drei Komponenten. Die erste Komponente ist eine neuartige Bildrepräsentation als Integral Image, welche sich günstig auf die Berechnung der Merkmale auswirkt. Die zweite Komponente ist ein auf dem AdaBoost von [6] basierender Lernalgorithmus. Die dritte Komponente ist der Einsatz einer großen Anzahl an schwachen Kaskaden-Klassifikatoren, die den Detektor darstellen.

Die Viola-Jones-Methode diente den sogenannten Aggregate Channel Features [31] als Inspiration. Diese führen als wesentliche Neuerung zusätzliche, auf dem Integral Image basierende, Merkmalsrepräsentationen ein. Durch diese zusätzliche Informationen wird die Genauigkeit der Objektdetektion weiter gesteigert, ohne dabei die Berechnungsdauer zu erhöhen.

Eine weitere Methode zur Objekterkennung in digitalen Bildern sind künstliche neuronale Netze, welche besonders in der jüngeren Vergangenheit immer mehr an Bedeutung gewonnen haben. Der Entwurf von künstlichen neuronale Netze ist dabei an dem biologischen Vorbild des Gehirns orientiert. Künstliche neuronale Netze werden in einer Reihe hierarchischer Modellschichten strukturiert, um den Prozess des maschinellen

Lernens durchzuführen. Deep Learning bezeichnet eine Klasse von künstlichen neuronalen Netzen, die über besonders viele Zwischenschichten (hidden layers) zwischen der Eingabe- und der Ausgabeschicht verfügen.

Die AlexNet Architektur von [14] aus dem Jahr 2012 ist das erste CNN Modell, welches den jährlichen Imagenet Large Scale Visual Recognition Challenge (ILSVRC) Wettbewerb [20] gewinnen konnte. Weiterhin erlangte die Architektur von [21] eine hohe Popularität. Diese knüpft an das AlexNet an, verwendet aber deutlich mehr Netzwerkschichten, welches mit einer gesteigerten Genauigkeit einhergeht. Die GoogLeNet Architektur von [25] gewann den ILSVRC Wettstreit im Jahr 2014. Sie besteht aus neu eingeführten Unterstrukturen, welche als Inception Blöcke bezeichnet werden und in der Inception-v2 [13] Architektur überarbeitet wurden.

Die in [11] eingeführte Residual Net (ResNet) Architektur unterbietet die bisherige Fehlerrate auf dem ILSVRC Wettbewerb um beinahe die Hälfte. Dies gelingt durch zusätzliche Verbindungen innerhalb der Netzwerkstruktur, welche die dem Lernvorgang zugrunde liegende Optimierung beschleunigen. Nach [12] kann die Inception-ResNet Architektur von [24], welche im Wesentlichen eine Kombination der ResNet und der Inception-v2 Architektur ist, eine noch einmal gesteigerte Genauigkeit erreichen.

Für spezielle Aufgaben wie die Objekterkennung wird ein CNN um einen Detektor erweitert. [16] und [18] entwerfen Detektoren, welche direkt aus den Merkmalen des CNNs Kandidaten für Bildbereiche bestimmen, die potentiell ein relevantes Objekt enthalten. Im Gegensatz dazu verwenden die in [19] und [4] entworfenen Detektoren ein zusätzliches Netzwerk namens Region Proposal Network (RPN), um zunächst Objekthypothesen zu ermitteln, welche anschließend in einer zweiten Verarbeitungsstufe unter Verwendung der CNN Merkmale endgültig klassifiziert werden. Im Vergleich mit dem direkten Ansatz resultiert die mehrstufige Objektdetektion unter Verwendung expliziter Objekthypothesen einerseits in höheren Genauigkeiten, aber auch andererseits in langsameren Verarbeitungszeiten.

Die bisher erwähnten Methoden der Objekterkennung beschränken sich auf einzelne Bilder. Da die betrachtete Anwendung eine Sequenz von Bildern verarbeitet, stellt die Methode der Hintergrundsubtraktion einen Ansatz dar, um effizient Bereiche zu bestimmen, welche sich von dem Hintergrund abheben. Dies trifft insbesondere auf solche Bereiche zu, die bewegte Objekte abbilden. Nach [28] wird hierzu zunächst ein Modell des Bildhintergrunds bestimmt. Aus einem Vergleich des jeweils aktuellen Kamerabilds mit dem Hintergrund lässt sich anschließend eine Maske des Vordergrundbereichs bestimmen. Wesentliches Unterscheidungsmerkmal der existierenden Ansätze stellt dabei die Art des Hintergrundmodells dar. Exemplarisch für den Einsatz von Medianfiltern ist der Ansatz von [3]. Für den selben Zweck verwendet der Wallflower-Algorithmus aus [27] einen linearen Wiener-Kolmogoroff-Filter [30]. Der Ansatz in [33] bildet den Bildhintergrund mittels eines Gaussian Mixture Model (GMM) ab.

### 3. Entwurf der CNN Architektur

CNN Modelle sind im Allgemeinen aus einem Merkmalsencoder und einem Detektor zusammengesetzt. Anschaulich bestimmt dabei der Merkmalsencoder zunächst statistische Merkmale, welche den Bildinhalt möglichst gut charakterisieren und gleichzeitig eine deutliche Reduktion der Datenmenge erzielen. Das Teilmodell des Detektors erzeugt schließlich die gewünschte Repräsentation der spezifischen Aufgabe der Bildverarbeitung. Dabei werden die abgebildeten Objekte üblicherweise mittels umhüllender Rechtecke, sogenannter Bounding Boxen, markiert.

#### 3.1. Merkmalsencoder

Für den Entwurf eines Merkmalsencoders enthält die Fachliteratur eine Vielzahl von Architekturen. Maßgebliche Auswahlkriterien sind dabei vor allem die erzielte Klassifikationsgenauigkeit und die Berechnungsdauer. [12] vergleichen einige exemplarische Architekturen untereinander.

Wird die Anzahl an Netzwerkschichten und die erzielte Fehlerrate verschiedener CNN Architekturen betrachtet, ergibt sich ein deutlicher Trend, dass eine höhere Anzahl an Netzwerkschichten die Fehlerrate reduzieren. Dieser Zusammenhang ist die Motivation für die ResNet Architektur [11], die es ermöglicht CNNs mit sehr vielen Netzwerkschichten zu verwenden. Allerdings führt eine hohe Anzahl an Netzwerkschichten dazu, dass das Netzwerk viele Parameter besitzt. Dies wirkt sich wiederum nachteilig auf die Berechnungsdauer aus.

[11] beschreiben, dass das Training von Modellen mit besonders vielen Netzwerkschichten in der Praxis oft gewissen Einschränkungen unterliegt. Dies wird darin begründet, dass aus vielen Netzwerkschichten eine stark verkettete mathematische Abbildung zwischen Modelleingang und -ausgang resultiert. Diese Verkettung ist für die gradientenbasierte Optimierung während des Prozess des maschinellen Lernens problematisch, da in der Folge abfallende Werte des Gradienten der Verlustfunktion in den Netzwerkschichten nahe des Eingangs entstehen (Vanishing Gradient Problem, [10]). In der Praxis wirkt sich dies in einer Verlangsamung des Lernvorgangs aus, soweit bis der Zeitaufwand schließlich nicht mehr praktikabel ist.

Zur Lösung dieses Problems schlagen [11] vor, die herkömmliche geradlinige Struktur von CNNs zu unterbrechen und sie durch Residual Blocks zu ersetzen. In Bild 2 ist eine grafische Veranschaulichung eines Residual Blocks zu sehen. Dabei bezeichnet  $X$  die Bildmerkmale einer beliebigen Netzwerkschicht,  $f(X)$  die der Netzwerkschicht zugeordnete Rechenoperation und  $h(X)$  die Ausgangsgrößen der Netzwerkschicht.

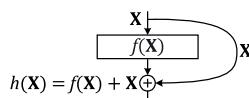


Bild 2: Grafische Darstellung eines Residual Blocks [11].

Durch den zusätzlichen parallelen Pfad existiert von jeder Netzwerkschicht ein Pfad zum Modellausgang ohne zusätzlich verkettete Abbildungen. Hierbei wird das Training von tiefen Modellen deutlich beschleunigt. Zudem zeigen die Autoren, dass die durch diesen Ansatz ermöglichten Modelltiefen zu deutlich gesteigerten Klassifikationsgenauigkeiten führen, welche für bestimmte Problemstellungen sogar die Leistungen menschlicher Probanden übertreffen. Aufgrund der hohen Modellgüte wird für die vorliegende Arbeit ein Merkmalsencoder nach [11] auf Grundlage der ResNet-Architektur in der Variante mit 101 Netzwerkschichten eingesetzt.

### 3.2. Objektdetektor

Ziel der Objektdetektion ist es Objekte in einem Bild mittels einer Bounding Box zu lokalisieren und zusätzlich eine Prädiktion des Objekttyps durchzuführen. Dabei können grundsätzlich unterschiedliche Objekttypen, wie beispielsweise Fahrzeuge oder Fußgänger, berücksichtigt werden. Zusätzlich ist die Anzahl der Objekte im Bild nicht bekannt und variiert fortlaufend. Zur Realisierung einer Objektdetektion mittels eines CNNs wird der Merkmalsencoder um eine Detektorstufe erweitert. Entsprechende Ansätze lassen sich in einstufige und zweistufige Detektoren unterscheiden, dabei schließen erstere unmittelbar aus den Merkmalen des Encoders auf das Vorhandensein von Objekten. Im Gegensatz dazu erfolgt im Falle der zweistufigen Detektoren zunächst eine grobe Bestimmung von Objekthypothesen, welche erst im zweiten Schritt zu einer genauen Objektdetektion verfeinert werden. Im Allgemeinen erreichen die zweistufigen Ansätze höhere Klassifikationsgenauigkeiten. So bietet entsprechend dem Vergleich in [12] der als Faster R-CNN bezeichnete Ansatz [19] nach derzeitigem Stand der Technik die höchste Modellgüte. Zusätzlich eignen sich die zweistufigen Verfahren aufgrund der expliziten Berücksichtigung von Objekthypothesen und dem damit einhergehenden modularen Aufbau besser, um vorhandenes Vorwissen über die Lage der gesuchten Objekte im Kamerabild zu berücksichtigen. Aufgrund der genannten positiven Eigenschaften wird im weiteren Verlauf der Faster R-CNN Detektor eingesetzt. Die Idee des Faster R-CNNs basiert auf den Arbeiten [9] und [8]. Wie in Bild 3 veranschaulicht, werden dabei zunächst die Merkmale des Encoders einem RPN zugeführt, welches die Regions of Interest (RoI) für die anschließende finale Regression und Klassifizierung vorschlägt. Dabei werden die Merkmale mit einem gleitenden Filter abgetastet, welcher sie auf eine verringerte Dimension abbildet und anschließend zwei Ausgabeschichten zuführt – der Regressions- und der Klassifikationsschicht. Die Regressionsschicht besitzt vier Ausgänge (Position im Bild sowie Höhe und Breite der Bounding Box) und die Klassifikationsschicht zwei (Wahrscheinlichkeit, dass es sich bei der Hypothese um ein Objekt beziehungsweise kein Objekt handelt). Zusätzlich werden an jedem Abtastort gleichzeitig  $k$  Hypothesen prognostiziert, die relativ zu  $k$  Referenzrahmen, welche als Anker bezeichnet werden, parametrisiert sind. Ein Anker ist zentriert im jeweiligen gleitenden Filter und besitzt ein definiertes Ausmaß und Seitenverhältnis. Dementsprechend besteht die Regressionsschicht des RPNs aus  $4k$  und die Klassifikationsschicht aus  $2k$  Ausgaben.

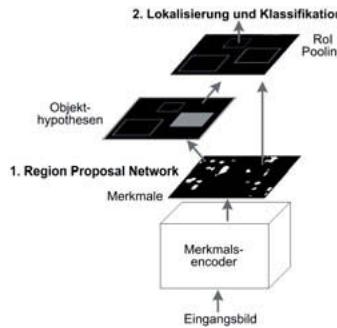


Bild 3: Zweistufige Verarbeitungskette des Faster R-CNN Objektdetektors nach [19]. Statt dem RPN wird in diesem Beitrag die Hintergrundsubtraktion zur Generierung von Objekthypothesen vorgeschlagen.

Beim Training des RPNs wird, dem zugrunde liegend, folgende Verlustfunktion minimiert:

$$L(\{\mathbf{p}_i\}, \{\mathbf{t}_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(\mathbf{p}_i, \mathbf{p}_i^*) + \lambda \frac{1}{N_{reg}} \sum_i \mathbf{p}_i^* L_{reg}(\mathbf{t}_i, \mathbf{t}_i^*).$$

Hierbei ist  $i$  der Index des Ankers,  $\mathbf{p}_i$  die prognostizierte Wahrscheinlichkeit, dass der Anker ein Objekt abbildet und  $\mathbf{p}_i^*$  das Ground Truth Label, welches gleich 1 ist, falls der Anker wirklich ein Objekt abbildet und 0, wenn dies nicht der Fall ist. Der Vektor  $\mathbf{t}_i$  repräsentiert die geschätzten vier Parameter der Bounding Box eines Ankers im Bild und  $\mathbf{t}_i^*$  korrespondiert ebenfalls mit dem zugehörigen Ground Truth Label. Der Klassifikationsverlust berechnet sich zu

$$L_{cls}(\mathbf{p}_i, \mathbf{p}_i^*) = -\mathbf{p}_i^* \log(\mathbf{p}_i) - (1 - \mathbf{p}_i^*) \log(1 - \mathbf{p}_i)$$

und der Regressionsverlust zu

$$L_{reg}(\mathbf{t}_i, \mathbf{t}_i^*) = g_{L_1}(\mathbf{t}_i - \mathbf{t}_i^*),$$

wobei

$$g_{L_1}(x) = \begin{cases} 0,5x^2 & \text{falls } |x| < 1 \\ |x| - 0,5 & \text{sonst} \end{cases}$$

die robuste  $L_1$ -Verlustfunktion darstellt, welche von [8] definiert wird. Sowohl der Klassifikations- als auch der Regressionsverlust werden mit den zugehörigen Konstanten  $N_{cls}$  beziehungsweise  $N_{reg}$  normiert und mit dem Parameter  $\lambda$  gewichtet.

In einem nächsten Schritt werden die Merkmale auf Basis der vorgeschlagenen Rols, welche eine beliebige Größe besitzen können, gebündelt, um sie auf eine einheitliche Dimension für die darauffolgende zweite Stufe des Detektors zu konvertieren. Dieser Schritt wird auch als Rol Pooling bezeichnet (siehe Bild 3). Die zweite Stufe des Detektors führt eine weitere Ver-

feinerung des Versatzes und Größe der Objekthypothesen vom RPN sowie eine finale Klassifizierung durch. Wesentlicher Unterschied dabei ist, dass in der ersten Stufe eine vollständige Abtastung der Encodermerkmale erfolgt und sich die Klassifikation auf die binäre Unterscheidung der Objektexistenz beschränkt, während in der zweiten Stufe ausschließlich Objekthypothesen mit ausreichend hoher Existenzwahrscheinlichkeit abgetastet werden und eine vollständige Typisierung erfolgt. Weiterhin wird in beiden Stufen eine Heuristik zur Unterdrückung von Nebenmaxima (non-maximum suppression) angewendet. Durch Schwellwertbildung auf Basis der Detektionskonfidenz entstehen anschließend die finalen Objektdetektionen.

Der Ablauf der Verarbeitung im Detektor lässt bereits erkennen, dass die Anzahl der zu untersuchenden Objekthypothesen einen wichtigen Modellparameter darstellt, welcher die Verarbeitungsdauer eines Bildes maßgeblich beeinflusst. Der nachfolgende Abschnitt betrachtet daher wie die Erzeugung von Objekthypothesen im Vergleich zu dem allgemeinen Faster R-CNN Ansatz aus [19] effizienter durchgeführt werden kann, wenn die besonderen Gegebenheiten der betrachteten Anwendung ausgenutzt werden.

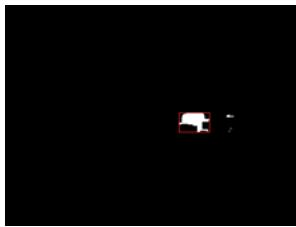
#### 4. Bestimmung von Objekthypothesen

Die Hintergrundsubtraktion (Background Subtraction) ist ein verbreitetes Verfahren, welches bei statischen Kameras anhand einer Sequenz von Kamerabildern bewegte Objekte vom Hintergrund separiert. Aus dem Vergleich aufeinanderfolgender Bilder lassen sich Schlussfolgerungen auf das Vorhandensein bewegter Objekte treffen. Üblicherweise wird dabei ein Modell des statischen Bildanteils, also des Hintergrunds, erstellt. Sobald ein bewegtes Objekt in das Bild tritt, weicht an der entsprechenden Stelle die bewegte Szene vom statischen Hintergrundmodell ab.

Grundsätzlich existieren verschiedene Ansätze zur Bestimmung eines Hintergrundmodells, die in [17] und [28] anschaulich zusammengefasst sind. In Anlehnung an [33] und [34] wird aufgrund der hohen Modellgüte bei gleichzeitig geringem Rechenaufwand eine gaußsche Mischverteilung zur Modellierung des statischen Hintergrunds eingesetzt. Dieses Verfahren bestimmt ein dicht aufgelöstes Hintergrundmodell, indem es für jeden Bildpunkt die Wahrscheinlichkeit der Zugehörigkeit zum Hintergrund berechnet. Die Wahrscheinlichkeit wird dabei gemäß folgender Gleichung durch eine gewichtete Überlagerung von Gaußverteilungen beschrieben:

$$\hat{p}(\mathbf{x}|BG) = \sum_{m=1}^M \hat{\pi}_m \mathcal{N}(\mathbf{x}; \hat{\mu}_m, \sigma_m^2 I)$$

Somit wird die mit  $\hat{\pi}_m$  gewichtete Summe der  $M$  Normalverteilungen  $\mathcal{N}$  gebildet, um die Wahrscheinlichkeit  $\hat{p}$ , dass ein gemessener Bildpunkt  $x$  zum Hintergrund  $BG$  gehört, abzubilden. Um Störungen wie Belichtungsänderungen oder Veränderungen im Bildhintergrund auszugleichen, wird das Hintergrundmodell fortlaufend an die aktuellen Aufnahmen adaptiert. Dabei werden die Parameter der Mischverteilung über ein rekursives Schätzverfahren nach [26] in jedem Zyklus neu ermittelt, wobei sich das Gewicht in der Vergangenheit liegender Aufnahmen über einen Vergessensfaktor reduziert. Als Ergebnis der Hintergrundsubtraktion entsteht zunächst ein Binärbild, welches zu einer Beschreibung der Objekthypothesen weiterverarbeitet wird. Nach dem Einsatz morphologischer Filter zur Rauschunterdrückung, generiert die Konturerkennung nach [23] eine direkte Darstellung der Objekthypothesen (siehe Bild 4).



(a) Detektion im Binärbild



(b) Resultierende Detektion im Eingangsbild

Bild 4: Beispieldetektion eines Fahrzeugs mittels der Hintergrundsubtraktion.

Eine Ermittlung der Objekthypothesen durch Anwendung der Hintergrundsubtraktion ermöglicht es den Faster R-CNN Detektor so zu modifizieren, dass die erste Detektorstufe, also das RPN, vollständig entfällt (vgl. Bild 3). Da die erste Detektorstufe aufgrund der vollständigen Abtastung der Merkmale deutlich rechenintensiver ist als die zweite Stufe, ergibt sich unmittelbar eine reduzierte Rechenzeit des Gesamtmodells. Zusätzlich lässt sich mit der ursprünglichen Architektur nur dann eine hohe Güte der Objektdetektion erzielen, wenn die zweite Detektorstufe eine hohe Anzahl ( $> 300$ ) an Hypothesen auswertet [19]. Die Hintergrundsubtraktion schränkt die Anzahl der Hypothesen deutlich stärker ein ( $< 10$ ), so dass der Rechenaufwand der zweiten Detektorstufe ebenfalls sinkt. Wie Bild 5 verdeutlicht prognostiziert die Hintergrundsubtraktion generell beliebige bewegte Objekte, wie beispielsweise Fußgänger, als Hypothesen. Solche Falschhypothesen sind unproblematisch, da sie zum einen in der zweiten Detektorstufe sofort verworfen werden und zum anderen zu erwarten ist, dass

es sich für den Anwendungsfall des MFDS bei den bewegten Objekten zum größten Teil nur um Fahrzeuge handeln kann.



Bild 5: Beispieldetektion eines Fußgängers mittels Hintergrundsubtraktion.

## 5. Analyse und Bewertung

Das in den vorherigen Abschnitten dargestellte CNN Modell benötigt einen mit Fahrzeugdetektionen gelabelten Datensatz zum Training und zur Identifikation der Netzparameter. Dieser Datensatz soll mit stationären Kameras aufgezeichnet worden sein, um die Verkehrsszene aus der Perspektive einer üblichen Überwachungsplattform, wie dem MFDS [1], abzubilden. Da kein öffentlicher verfügbarer Datensatz existiert, welcher diese Eigenschaften aufweist, wird ein eigener Datensatz mit 7481 Bildern mit markierten Fahrzeugen erstellt. Aufgrund der geringen Größe dieses selbst erstellten Datensatzes wird ein in der Literatur übliches Verfahren nach [32] angewandt, welches das unmodifizierte CNN Modell zunächst auf dem öffentlich verfügbaren und umfangreichen Datensatz „MS-COCO“ [15] zur allgemeinen Objektdetektion vortrainiert. Damit lassen sich die Modellparameter vorinitialisieren, erst diese Vereinfachung ermöglicht die robuste Identifikation des CNN Modells auf dem eigenen Datensatz zur Fahrzeugdetektion. Insgesamt werden 80% der aufgenommenen Kamerabilder für die Modellidentifikation verwendet, während 20% für die nachfolgende Auswertung vorgehalten werden.

Die Auswertung erfolgt anhand der Gütekriterien in [7], wobei ausschließlich sich bewegende Fahrzeuge berücksichtigt werden. Für eine erfolgreiche Detektion müssen die durch das CNN erzeugten Bounding Boxen mindestens zu 70% mit den durch per Hand erstellten Ground Truth-Annotationen überlappen. Weiterhin werden detektierte Fahrzeuge erst dann zur Auswertung herangezogen, wenn die Höhe der überdeckten Teilregion mindestens 60 Bildpunkte beträgt.

Die Analyse betrachtet die Anzahl der richtig positiven (RP), falsch positiven (FP), falsch negativen (FN) und richtig negativen (RN) Detektionen auf dem Testdatensatz. Aus diesen

Werten lässt sich die Genauigkeit (Precision) sowie die Trefferquote (Recall) folgendermaßen ermitteln:

$$\text{Genauigkeit} = \frac{\text{RP}}{\text{RP} + \text{FP}} \in [0, 1]$$

$$\text{Trefferquote} = \frac{\text{RP}}{\text{RP} + \text{FN}} \in [0, 1]$$

Sowohl die Genauigkeit als auch die Trefferquote des idealen Detektors beträgt 1. Allgemein ergibt sich durch diese Gütemaße ein Zielkonflikt, bei welchem der Ausgleich zwischen beiden Werten von der Wahl des Schwellwertes für die Konfidenz am Modellausgang abhängt. Bild 6 trägt die sich ergebenden Werte der Gütemaße sowohl für die originale Architektur des Faster R-CNN Ansatzes als auch für die in dieser Arbeit verwendeten Modifikationen gegenüber. Hieraus ist ersichtlich, dass die Genauigkeit für das Modell unter Verwendung der Hintergrundsubtraktion signifikant früher abfällt, als für das ursprüngliche Modell, welches nahezu einem idealen Detektor entspricht.

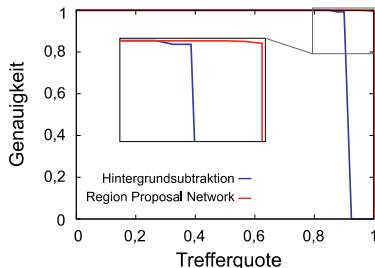


Bild 6: Genauigkeit und Trefferquote des verwendeten Modells ausgewertet auf dem Datensatz zur Fahrzeugdetektion

Um die Modellgüte auf einen einzelnen Wert abzubilden, schlägt [5] vor, die in Bild 6 aufgetragenen Genauigkeiten zu einer mittleren Genauigkeit, der sogenannten Mean Average Precision (mAP), zu verrechnen. Tabelle 1 führt die Genauigkeiten auf, und enthält zusätzlich die durchschnittliche Rechenzeit der vollständigen Verarbeitungskette als weiteres Kriterium.

Tabelle 1: Vergleich der Hintergrundsubtraktion mit dem RPN.

	mAP [%]	Rechenzeit [ms]
Region Proposal Network	99,89	407
Hintergrundsubtraktion	90,84	313

Es zeigt sich, dass durch den Einsatz der Hintergrundsubtraktion zur Erzeugung von Objekt-hypothesen die Modellgüte nach mAP um etwa 9% abnimmt, während die Berechnungsge-schwindigkeit um 28,78 % steigt. Da beide Modelle eine ausreichende Detektionsgüte auf-weisen, welche eine zuverlässige Positionsbestimmung der Fahrzeuge in den nachgelager-ten Verarbeitungsschritten ermöglicht [2], ergibt sich aus der eingesparten Rechenzeit di-rekt eine Reduktion der Hardwareanforderungen des Verkehrsüberwachungssystems.

## 6. Zusammenfassung und Ausblick

Dieser Beitrag betrachtet die automatische Detektion von Fahrzeugen mittels eines stati-schen Kamerasystems. Hierzu wird das aus der Literatur bekannte Verfahren Faster R-CNN [19] dahingehend modifiziert, dass es die besonderen Eigenschaften von sequenziell aufge-zeichneten Kamerabildern mit statischem Hintergrund ausnutzt, um die Rechenzeit des Ver-fahrens signifikant zu reduzieren. Auf dieser Grundlage wird die Architektur eines CNN-Modells hergeleitet und unter Zuhilfenahme eines für diesen Zweck aufgezeichneten Daten-satzes bewertet. Dabei zeigt sich die grundsätzliche Eignung des skizzierten Verfahrens für den Einsatz in der Verkehrsüberwachung.

Aus den erzielten Ergebnissen geht hervor, dass sich für das in dieser Arbeit vorgeschlage-ne Verfahren eine moderate Abnahme der Detektionsgüte im Vergleich zu dem ursprüngli-chen Faster R-CNN Modell ergibt. In zukünftigen Arbeiten wird daher untersucht, ob dieser Effekt durch eine geringere Einschränkung des Suchraumes vermieden werden kann. Eine mögliche Realisierung besteht darin, pro Objekthypothese nicht nur eine einzige Bounding Box sondern auch eine geringe Anzahl zusätzlicher Boxen mit leicht veränderten Dimensio-nen und Seitenverhältnissen zu berücksichtigen. Ebenfalls stellt die Analyse alternativer Teilmodelle zur Merkmalsextraktion mit dem Ziel einer zusätzlichen Reduktion des Rechen-aufwands einen Schwerpunkt zukünftiger Arbeiten dar. Weiterhin gilt es die Robustheit des Ansatzes gegenüber wechselnden Wetter- und Lichtverhältnissen zu analysieren.

## Danksagung

Diese Arbeit wurde zum Teil finanziert durch das Land NRW und den europäischen Fonds für regionale Entwicklung (EFRE) 2014-2020 im Rahmen des Projekts InVerSiV unter der Kennnummer EFRE-0800418. Die Autoren danken Herrn Bernd Möllenbeck sowie der Firma Wilhelm Schröder GmbH für ihre Unterstützung.

## 7. Literaturangaben

- [1] Multi Funktionales Detektions System. [www.mfds.eu/de/das-mfds](http://www.mfds.eu/de/das-mfds). Abgerufen am: 26.10.2018
- [2] Choi, W.: Near-online multi-target tracking with aggregated local flow descriptor. Proceedings of the IEEE International Conference on Computer Vision, 2015, S. 3029–3037
- [3] Cucchiara, R., Grana, C., Piccardi, M., Prati, A.: Detecting moving objects, ghosts, and shadows in video streams. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003
- [4] Dai, J., Li, Y., He, K., Sun, J.: R-fcn: Object detection via region-based fully convolutional networks. <http://arxiv.org/pdf/1605.06409v2>, 2016
- [5] Everingham, M., Van Gool, L., Williams, C.K., Winn, J., Zisserman, A.: The pascal visual object classes (voc) challenge. International Journal of Computer Vision, 88(2), 2010, S. 303–338
- [6] Freund, Y., Schapire, R.E.: A decision-theoretic generalization of on-line learning and an application to boosting. Journal of Computer and System Sciences, 55(1), 1997, S. 119–139
- [7] Geiger, A., Lenz, P., Urtasun, R.: Are we ready for autonomous driving? the kitti vision benchmark suite. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2012, S. 3354–3361
- [8] Girshick, R.: Fast r-cnn. Proceedings of the IEEE International Conference on Computer Vision, 2015, S. 1440–1448
- [9] Girshick, R., Donahue, J., Darrell, T., Malik, J.: Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014, S. 580–587
- [10] Goodfellow, I., Bengio, Y., Courville, A.: Deep learning. Cambridge, Massachusetts and London, England: MIT Press 2016
- [11] He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, S. 770–778
- [12] Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., Fischer, I., Wojna, Z., Song, Y., Guadarrama, S., Murphy, K.: Speed/accuracy trade-offs for modern convolutional object detectors. <http://arxiv.org/pdf/1611.10012v3>, 2017

- [13] Ioffe, S., Szegedy, C.: Batch normalization: Accelerating deep network training by reducing internal covariate shift. Computing Research Repository, 2015
- [14] Krizhevsky, A., Sutskever, I., Hinton, G.E.: Imagenet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 2017, S. 84–90
- [15] Lin, T.Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., Zitnick, C.L.: Microsoft coco: Common objects in context. European Conference on Computer Vision, 2014, S. 740–755
- [16] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y., Berg, A.C.: Ssd: Single shot multibox detector. European Conference on Computer Vision, 2016, S. 21–37
- [17] Piccardi, M.: Background subtraction techniques: a review. IEEE International Conference on Systems, Man & Cybernetics, 2004, S. 3099–3104
- [18] Redmon, J., Divvala, S., Girshick, R., Farhadi, A.: You only look once: Unified, real-time object detection. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, S. 779–788
- [19] Ren, S., He, K., Girshick, R., Sun, J.: Faster r-cnn: towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(6), 2017, S. 1137–1149
- [20] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., Fei-Fei, L.: Imagenet large scale visual recognition challenge. <http://arxiv.org/pdf/1409.0575v3>, 2015
- [21] Simonyan, K., Zisserman, A.: Very deep convolutional networks for large-scale image recognition. <http://arxiv.org/pdf/1409.1556v6>, 2014
- [22] Statistisches Bundesamt: Unfallentwicklung auf deutschen Straßen 2017
- [23] Suzuki, S., be, K.: Topological structural analysis of digitized binary images by border following. Computer Vision, Graphics, and Image Processing 30(1), 1985, S. 32–46
- [24] Szegedy, C., Io\_e, S., Vanhoucke, V., Alemi, A.: Inception-v4, inception-resnet and the impact of residual connections on learning. Computing Research Repository, <http://arxiv.org/abs/1602.07261>, 2016
- [25] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A.: Going deeper with convolutions. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015, S. 1–9
- [26] Titterington, D.M.: Recursive parameter estimation using incomplete data. Journal of the Royal Statistical Society, Series B (Methodological), 1984, S. 257–267

- [27] Toyama, K., Krumm, J., Brumitt, B., Meyers, B.: Wallflower: Principles and practice of background maintenance. Proceedings of the 7th IEEE International Conference on Computer Vision, vol. 1, 1999, S. 255–261
- [28] Uddagiri, C., Das, T.: A survey of techniques for background subtraction and traffic analysis on surveillance video. Universal Journal of Applied Computer Science and Technology, 1(3), 2011, S. 107–113
- [29] Viola, P., Jones, M.: Rapid object detection using a boosted cascade of simple features. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2001, S. 511–518
- [30] Wiener, N.: Extrapolation, interpolation, and smoothing of stationary time series: with engineering applications, 1949
- [31] Yang, B., Yan, J., Lei, Z., Li, S.Z.: Aggregate channel features for multi-view face detection. IEEE International Joint Conference on Biometrics, 2014, S. 1–8
- [32] Yosinski, J., Clune, J., Bengio, Y., Lipson, H.: How transferable are features in deep neural networks?. Advances in neural information processing systems, vol. 27, 2014, S. 3320–3328
- [33] Zivkovic, Z.: Improved adaptive gaussian mixture model for background subtraction. Proceedings of the 17th International Conference on Pattern Recognition, vol. 2, 2004, S. 28–31
- [34] Zivkovic, Z., van der Heijden, F.: Efficient adaptive density estimation per image pixel for the task of background subtraction. Pattern Recognition Letters, 27(7), 2006, S. 773–780

# Analyse und Unterstützung von Fahrereingriffen in dynamischen, kritischen Situationen beim hochautomatisierten Fahren

M.Sc. Thang Nguyen, Prof. Dr.-Ing. Steffen Müller,  
Fachbereich Kraftfahrzeugtechnik, Technische Universität Berlin

## Kurzfassung

Im Zuge der fortschreitenden Automatisierung von Fahrzeugen ist das hochautomatisierte Fahren die nächste Stufe in der Fahrzeugentwicklung. Durch die 2016 in Kraft getretene Änderung des Wiener Übereinkommens über den Straßenverkehr sind hoch- und vollautomatisierte Fahrzeuge erlaubt, es wird jedoch gefordert, dass der Fahrer jederzeit in der Lage sein soll, das System durch einen Eingriff zu übersteuern oder auszuschalten. Insbesondere in hochdynamischen Fahrsituationen können solche Eingriffe aber zu kritischen Situationen führen. Damit stellt sich die Frage, ob und ab wann Fahrereingriffe in die hochautomatisierte Fahrzeugregelung kritisch sind und wie der Fahrer assistiert werden kann, sodass sicherheitskritische Fahrereingriffe vermieden werden können.

Um diese Forschungsfragen zu beantworten, werden im Rahmen dieses Projektes Probandenstudien in einem Fahrsimulator für unterschiedliche Fahrszenarien durchgeführt. Das hier vorgestellte Fahrszenario ist ein Ausweichmanöver auf zwei hintereinander folgende Hindernisse. Die Ergebnisse der Studie zeigen auf, bis zu welchen Randbedingungen ein Fahrereingriff noch unkritisch ist und wie eine Assistenz zur Vermeidung kritischer Eingriffe gestaltet werden müsste. Mit diesen Ergebnissen wird ein Konzept für den Assistenten entwickelt und vorgestellt. Diese Assistenzfunktion wurde in der numerischen Simulationsumgebung IPG CarMaker implementiert und es wird durch numerische Simulationsergebnisse gezeigt, wie sich die Assistenz auf die Fahrsicherheit für das betrachtete Ausweichmanöver auswirkt.

## 1. Einleitung und Motivation

Laut der BAS<sup>1</sup> und dem VDA<sup>2</sup> übernimmt das hochautomatisierte Fahren vollständig die Quer- und Längsführung des Fahrzeuges für einen gewissen Zeitraum oder eine spezifische Situation. Der Fahrer kann sich vom Verkehrsgeschehen abwenden und muss das System nicht

---

<sup>1</sup> BAS – Bundesanstalt für Straßenwesen

<sup>2</sup> VDA – Verband der Automobilindustrie

dauerhaft überwachen. Er muss jedoch jederzeit in der Lage sein, die Fahraufgabe zu übernehmen [1, 2]. Eine solche Übernahme könnte jedoch zu gefährlichen Szenarien führen, in der die Fahrer mit der Situation überfordert sind. Daher liegt es nahe, sich mit Rückübernahmen zu beschäftigen, die die automatisierte Fahrfunktionen übersteuern oder deaktivieren. Denn um das Problem einer sicherheitsgefährdenden Fahrerübernahme zu begegnen, muss ein assistierender Übergang zwischen dem Eingriffs- und Übernahmezeitpunkt existieren.

Wird der aktuelle Stand der Forschung zu Fahrereingriffen betrachtet, die während einer hoch-automatisierten Fahrt passieren, konzentrieren sich die Untersuchungen bisher zu Übergaben der Fahrzeugkontrolle, die systemseitig initiiert werden, meist in Situationen mit geringer Fahrdynamik stattfinden und sich mit Fahrern beschäftigen, die durch eine Nebentätigkeit abgelenkt waren [4]. Es kann aber zu Übernahmesituationen führen, die fahrdynamisch anspruchsvoll sind und in denen der Fahrer nicht abgelenkt ist. Es ist unter anderem zu überprüfen, ob die Fahrer ihrer Rolle als Rückfalllösung bei der Übernahme der Fahrzeugführung gerecht werden können oder, ob sich daraus Risiken entwickeln, die die Fahrzeugstabilität und somit die Fahrzeugsicherheit gefährden [3]. Daraus ergeben sich neue Forschungsfragen, die sich mit Übernahmesituationen des Fahrers beschäftigen und die bisher noch nicht diskutiert wurden:

1. Bis zu welcher kritischen Fahrsituation gelingt es dem Fahrer eine Übernahme nicht mehr sicher zu gestalten?
2. Wie kann ein Eingriff in die Fahrzeugführung während einer automatisierten Fahrt durch ein Assistenzsystem unterstützt werden, das unangemessene Eingriffe des Fahrers so modifiziert, dass eine sichere Quer- und Längsführung gewährleistet ist?

Um diese Fragen zu beantworten, wird in dieser Untersuchung ein kritisches, unfallrelevantes Fahrszenario betrachtet. Des Weiteren wird ein Konzept für einen Assistenten vorgestellt, welcher simulativ mit einem Fahrermodell und einem Gesamtfahrzeugsimulationsprogramm getestet wird und eine mögliche Verbesserung der Fahrleistung aufzeigt.

## 2. Untersuchungsmethodik

Das in dieser Arbeit zu untersuchende Fahrszenario beschreibt ein doppeltes Ausweichmanöver (Bild 1). Im ersten Abschnitt des Szenarios fährt das Fahrzeug der Versuchsperson (nachfolgend als Ego-Fahrzeug bezeichnet) automatisiert hinter einem Führungsfahrzeug, im zweiten Abschnitt erfolgt ein Eingriff in die Fahrzeugführung durch die Fahrer. Während der automatisierten Fahrt wird die Sicht des Fahrers nach vorne beschränkt. Ab einem definierten Streckenabschnitt erscheint ein Hindernis in Form eines Autounfalls. Das Führungsfahrzeug wechselt daraufhin in die linke Spur und eröffnet somit dem Fahrer des Ego-Fahrzeugs die Sicht

auf das Hindernis. Nachdem das Führungsfahrzeug dem ersten Hindernis ausgewichen ist, erfolgt aufgrund eines zweiten Hindernisses in Form einer Wanderbaustelle ein zweites Ausweichmanöver. Das Ego-Fahrzeug muss das gleiche Fahrmanöver ausführen, um dem Hindernis auszuweichen. Beide Ausweichmanöver sind hinsichtlich ihrer gefahrenen Trajektorie symmetrisch. Der kritische Abschnitt beginnt mit der Eröffnung der Sicht auf das Hindernis und endet, wenn das Ego-Fahrzeug wieder auf der Ausgangsspur angekommen ist

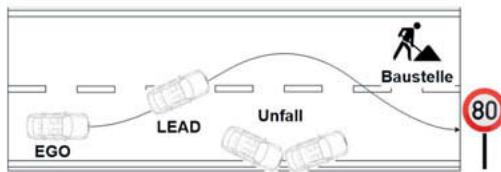


Bild 1: Szenario doppeltes Ausweichmanöver (angelehnt an ISO 3882:2)

Um objektiv das Gefährdungspotenzial, das zum Zeitpunkt eines Eingriffs durch den Fahrer besteht, zu ermitteln, werden in dieser Arbeit zwei fahrdynamische Größen betrachtet: Time-Headway (THW) und die Kraftschlussausnutzung (KA). Es gilt: je kleiner THW und je größer KA, desto kritischer die Situation. Die Kritikalität des Fahrszenarios hängt von der gefahrenen Ausweichtrajektorie des Ego-Fahrzeugs ab. Je näher sich die Trajektorie den Hindernissen annähert und je größer die gefahrene Krümmung, desto kritischer gestaltet sich die Fahrsituation.

Tabelle 1: Kombinationen des Ausweichtestszenarios für unterschiedliche Kritikalitäten

	Sze-nario	THW	KA
Teilmanöver 1	A	unkritisch	unkritisch
	B	kritisch	unkritisch
	C	unkritisch	kritisch
	D	kritisch	kritisch
Teilmanöver 2	E	unkritisch	unkritisch
	F	kritisch	unkritisch
	G	unkritisch	kritisch
	H	kritisch	kritisch

Insgesamt werden zwei Stufen für THW und zwei Stufen für KA definiert, sodass vier unterschiedlich kritische Ausweichtrajektorien gefahren werden können. Die systeminitiierte Aufforderung an die Versuchsperson, die Fahrzeugführung zu übernehmen, erfolgt in beiden symmetrischen Teilmanövern. Daraus ergeben sich also insgesamt acht Testszenarien, um das Ausweichverhalten der Versuchspersonen auszuwerten (Tabelle 1).

Die Ergebnisse der Versuche geben Aufschluss darüber, wie sich das Ausweichverhalten der Versuchspersonen gestaltet, wenn die Kontrolle vom Fahrer während eines automatisierten Ausweichmanövers übernommen wird. Die in den Experimenten ausgeübten Lenkradmomente, die Unfallhäufigkeit in Abhängigkeit von THW und KA und die Fahrleistung der Probanden werden herangezogen, um die genauen Ausprägungen dieser Assistenz zu bestimmen. Die Fahrleistung, die ein Fahrer nach einem Eingriff zeigt, wird durch den Grad der Abweichung zum Optimum ermittelt. Dabei wird davon ausgegangen, dass die automatisierte Fahrfunktion eine optimale Fahrzeugführung gewährleistet.

### 3. Experimentelle Versuchsumgebung

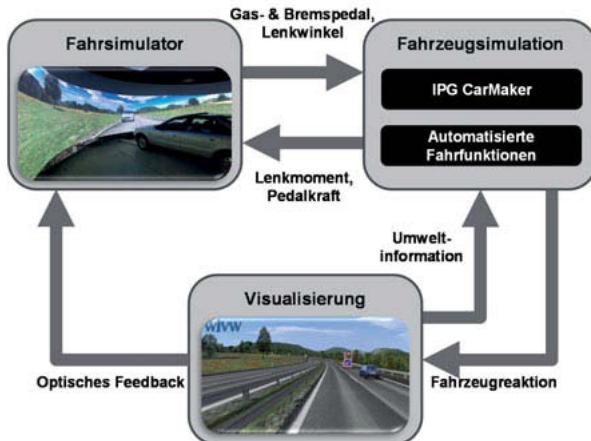


Bild 2: Übersicht zum Aufbau des Fahrsimulators

Für die im Rahmen dieses Projektes durchzuführenden Probandenstudien wird der Fahrsimulator der TU Berlin des Fachgebiets Kraftfahrzeuge verwendet. Der Aufbau des Fahrsimulators lässt sich in drei Bereiche aufteilen (Bild 2): die Visualisierung, die Simulation der Fahrzeugdynamik und die Hardware zur Steuerung des Fahrsimulators. Als Mock-up dient ein reales Fahrzeug samt Karosserie und Innenraum. Von hier aus bedienen die Probanden den Fahrsimulator durch Lenkwinkel-, Gaspedal- und Bremspedaleingaben. Um das Fahrzeugverhalten möglichst realitätsnah abzubilden, werden die Fahrereingaben in die Fahrzeugsimulationssoftware IPG CarMaker weitergeleitet. Entsprechend der berechneten Fahrzeugreaktion des Gesamtfahrzeugsimulationsmodells wird zum einen die Bewegung des Fahrzeugs durch die Visualisierungssoftware SILAB<sup>3</sup> dargestellt und zum anderen werden Lenkradmomente und Pedalkräfte an die Bedienelemente übergeben. Die Visualisierung geschieht über eine 180°-Leinwand. Eine solche Projektion unterstützt das periphere Sehen des Menschen und erhöht somit die Wahrnehmung der Geschwindigkeit und damit die Immersion. Zusätzlich zur Visualisierung wird der Innenrückspiegel und der linke Außenspiegel durch eine Rückprojektion erweitert. Eine Darstellung des Fahrszenarios im rechten Außenspiegel ist aufgrund der baulichen Begrenzung nicht möglich. Um die im vorherigen Kapitel beschriebenen Fahrszenarien zu fahren,

<sup>3</sup> Fahrsimulationssoftware des Würzburger Instituts für Verkehrswissenschaften (WIVW GmbH)

müssen hochautomatisierte Fahrfunktionen im Fahrsimulator implementiert werden. Für die automatisierte Längsdynamikregelung wird ein Modell verwendet, welches automatisiert die Geschwindigkeit und den Abstand zum vorausfahrenden Fahrzeug reguliert [5]. Die Querregelung zur Durchführung des zweiten Fahrszenarios wird im Kapitel 5 näher erläutert.

#### 4. Ergebnisse der Probandenstudie

Im Folgenden werden die Ergebnisse der Probandenstudie zum Ausweichmanöver vorgestellt. Insgesamt nahmen 60 Personen an der Studie teil.

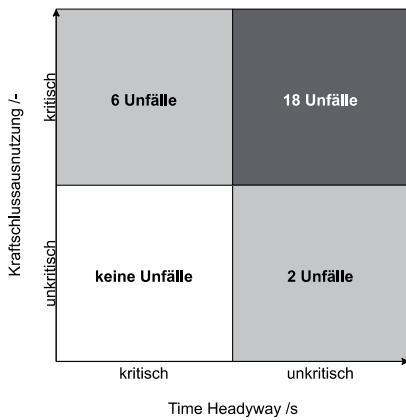


Bild 3: Anzahl der Unfälle für unterschiedliche Kritikalitäten des Ausweichmanövers bei 60 Versuchspersonen

Im Bild 3 ist die Anzahl der Unfälle in Relation zu THW und KA dargestellt. Es zeigt sich, dass die Probanden bei einem unkritischen THW-Wert und einem kritischen KA-Wert eher dazu neigen, Unfälle zu verursachen. Dabei ist anzumerken, dass 16 dieser 18 Unfälle durch einen Zusammenstoß mit dem ersten Hindernis ausgelöst wurde. Die Fahrer lenken bei dem ersten Teilmanöver viel zu früh ein, sobald eine fahrdynamisch anspruchsvolle Trajektorie (nahe der Kraftschlussgrenze) mit ausreichend Abstand zum Hindernis (hoher THW-Wert) gefahren wird. Um solche Unfälle zu vermeiden, ist es zweckdienlich, einen Assistenten zu entwerfen, der sicherheitsgefährdete Fahrereingriffe korrigiert.

Für die genaue Ausprägung des Eingriffsassistenten wurden das Handmoment, die Querbeschleunigung und der Pfad betrachtet, die während des Fahrereingriffs entstehen. In Bild 4 sind die gemittelten Verläufe aller 60 Versuchspersonen beispielhaft für das Fahrszenario D

dargestellt. Da der zu entwerfende Eingriffsassistent in der numerischen Entwicklungsumgebung IPG CarMaker simulativ getestet und bewertet wird, wurde das Fahrermodell von IPG derart parametriert, dass es simulativ das aus der Probandenstudie gemittelte Fahrverhalten möglichst genau widerspiegelt (Bild 4).

Ab einem longitudinalen Weg von 1483 m (Übernahmezeitpunkt) greift der Fahrer in die Fahrzeugführung ein. Gleichzeitig wird die Automation abgeschaltet. Während eines Eingriffes ist zu erkennen, dass ab dem Streckenpunkt 1490 m der laterale Weg vom Idealpfad um circa 0,3 m abweicht. Bei den Querbeschleunigungsverläufen der simulativen und realen Eingriffe werden größere Werte als beim Idealverlauf erreicht. Das wiederum erhöht den Grad der Kraftschlussausnutzung und somit die Fahrzeuginstabilität.

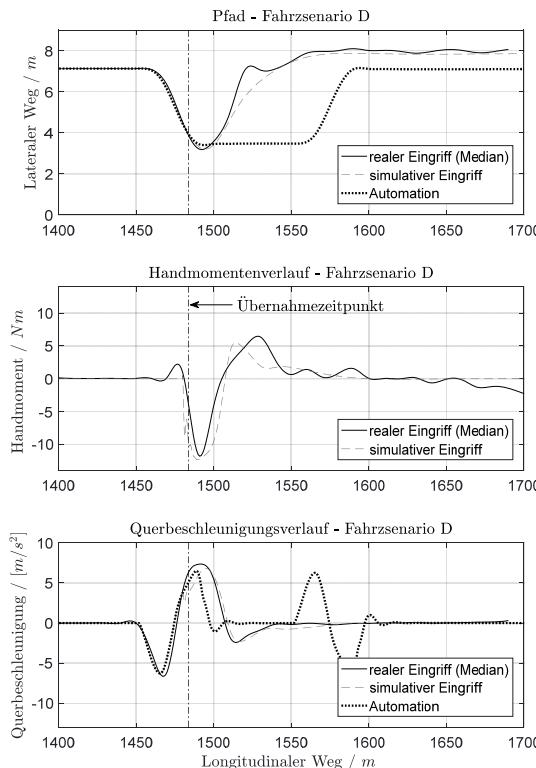


Bild 4: Verlauf des Pfades, des Handmoments und der Querbeschleunigung des Fahrzeugszenarios D, Vergleich zwischen dem real gemittelten und dem simulierten Fahrereingriffen und den idealen Verläufen der Automation

## 5. Struktur der Fahrzeugführungsregelung mit assistierten Fahrereingaben

Die hochautomatisierten Fahrfunktionen wurden in den Probandenstudien so umgesetzt, dass sich die Automation beim Eingriff des Fahrers abschaltet. Im Rahmen der Entwicklung des Eingriffsassistenten wurde die Funktionalität dahingehend verändert, dass sich während eines Eingriffes die automatisierte Fahrfunktion nicht abschaltet, sondern den Fahrer bei der Fahrzeugführung unterstützen soll. Durch gezieltes Erzeugen von Momenten am Lenkrad wird der Fahrer zum richtigen Bedienverhalten hingeführt, sodass Fahrzeuginstabilitäten durch falsche Fahrereingaben vermieden werden. Jedoch wird der Fahrer jederzeit in der Lage sein, die Funktionalität zu übersteuern.

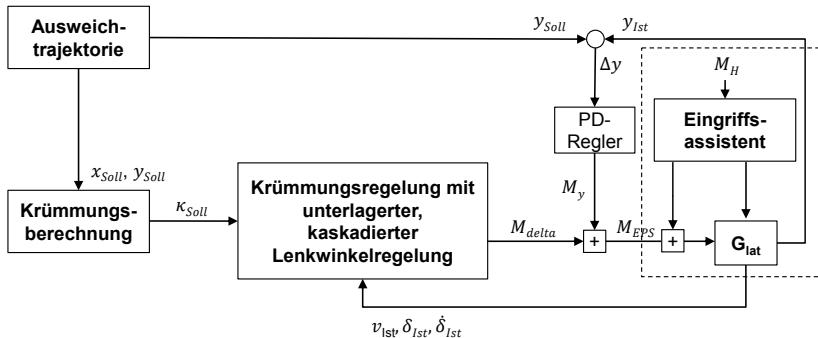


Bild 5: Struktur der Fahrzeugquerführungsregelung für das automatisierte Ausweichmanöver

Die verwendete Regelungsstruktur, um das doppelte Ausweichmanöver vollautomatisiert zu fahren und um das Konzept des Eingriffsassistenten darzustellen, ist in Bild 5 zu sehen. Der in dieser Arbeit umgesetzte Regelkreis basiert auf den Veröffentlichungen von Walter [6] und Rathgeber [7]. Es handelt sich um eine kaskadierte Positions- und Geschwindigkeitsrückführung des Lenkwinkels  $\delta_v$  (Anhang A1). Als zusätzliche Regelgröße wird die laterale Positionsabweichung  $\Delta y$  bezüglich der Trajektorie erfasst, um Querabweichungen von der Zieltrajektorie asymptotisch zu unterdrücken. Die gesamte Stellgröße berechnet sich somit aus dem Ausgang der Krümmungs- und Querabweichungsregelung. Ziel dieser Regelung ist es, das Fahrzeug einer geplanten Trajektorie zu führen. Die Stellgröße am Ausgang des Fahrzeugführungsreglers ist das EPS-Motormoment  $M_{EPS}$ . Die in der Simulation verwendete EPS überträgt die Lenkkraft des Elektromotors achsparallel zur Zahnstange. Eine hohe Übertragung der Zahnstangenkraft vom Elektromotor sowie ein präzises Ansprechverhalten der Lenkung zeichnen dieses System aus. Das vom Fahrer übertragene Moment  $M_H$  wird als Störung betrachtet. Die Regelstrecke des Regelkreises ist mit  $G_{lat}$  gekennzeichnet und bildet die Dynamik des Fahrzeugs und der Lenkung ab. Das laterale Verhalten des verwendeten Querdynamikmodells des Fahrersimulators der TU Berlin wird als PT2-Glied approximiert:

$$G_{lat}(s) = \frac{K_{s,lat}}{1 + 2d_{lat}T_{lat}s + T_{lat}^2s^2}$$

Die Parameter  $K_{s,lat}$ ,  $d_{lat}$  und  $T_{lat}$  der Regelstrecke werden nach [10] identifiziert und sind dem Anhang A.2. zu entnehmen. Die Berechnung der Ausweichtrajektorie basiert auf ein Polynom 5. Ordnung. Dieser Ansatz zur Berechnung einer Ausweichtrajektorie für ein stehendes

Hindernis weist die kürzeste Manöverlänge auf und besitzt im Verlauf keine Krümmungssprünge [8]. Aus der berechneten Trajektorie lässt sich eine Sollkrümmung  $\kappa_{Soll}$  und ein lateraler Sollweg  $y_{Soll}$  berechnen, die als Führungsgrößen für die Regelung verwendet werden. Die Regelparameter  $k_p$ ,  $k_d$  der Krümmungsregelung und  $k_{p,y}$ ,  $T_{d,y}$  des idealen PD-Reglers für die laterale Querabweichung wurden iterativ bestimmt (Anhang A.3). Die Stabilität der modellierten Fahrzeugquerführungsregelung ist im Anhang A.4 nachgewiesen.

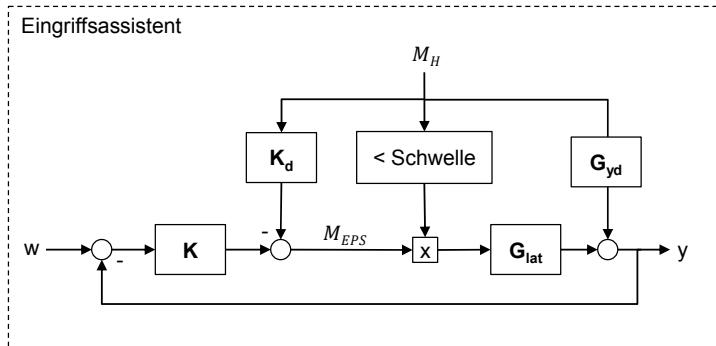


Bild 6: Konzept des Eingriffsassistenten für das automatisierte Ausweichmanöver

Das Konzept des Eingriffsassistenten wird durch eine Störgrößenaufschaltung realisiert (Bild 6). Voraussetzung ist, dass die Störgröße (Handmoment  $M_H$ ) jederzeit messbar ist. Neben der Rückführung über den Regler  $K$  wird eine Vorwärtssteuerung mit der Übertragungsfunktion  $K_d$  verwendet, welche wie folgt berechnet wird:

$$K_d = \frac{G_{yd}}{G_{lat}}$$

Die Übertragungsfunktion  $G_{yd}$  wurde analog Anhang A.2 durch eine Sprungantwort ermittelt und ist somit bekannt. Bei einem Lenkradeingriff des Fahrers wird das Handmoment mit einem Schwellwert verglichen. Überschreitet das Handmoment diesen Wert, so wird die Stellgröße  $M_{EPS}$  zu null gesetzt und der Fahrer übernimmt wieder die Fahrzeugführung. Somit versucht die Regelung bis zu einem gewissen Grad das Handmoment als Störgröße zu kompensieren.

## 6. Simulationsergebnisse

Im Folgenden werden die Simulation und Auswertung des numerisch modellierten Eingriffsassistenten anhand des Fahrszenarios D präsentiert.

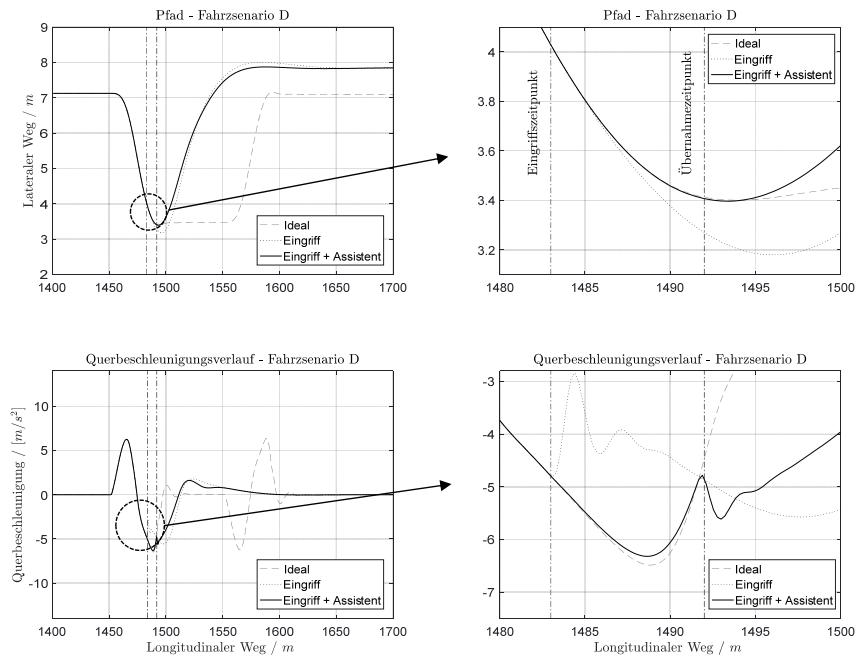


Bild 7: Verlauf des Pfades und der Querbeschleunigungsverläufe des Fahrzenarios D, Vergleich zwischen simulativen Eingriff ohne und mit Assistenten

Im Bild 7 werden die Pfade und Querbeschleunigungsverläufe zwischen dem simulierten Eingriff mit und ohne Assistenten verglichen. In der vergrößerten Darstellung (Bild 8, rechte Abbildungen) sind die Eingriffs- und Übernahmezeitpunkte des Fahrers dargestellt, wenn er mit dem Eingriffsassistenten fährt. Zwischen diesen beiden Zeitpunkten wirkt die Störgrößenaufschaltung. Überschreitet das Handmoment des Fahrers den definierten Schwellenwert, so wird das EPS-Moment ausgeschaltet und der Fahrer übernimmt vollständig die Fahrzeugführung (Bild 8). Es ist zu erkennen, dass bei einem assistierten Eingriff das Fahrzeug dem idealen Verlauf bis zur Übernahme sehr gut folgen kann. Auch werden nahezu gleiche Querbeschleunigungswerte erreicht.

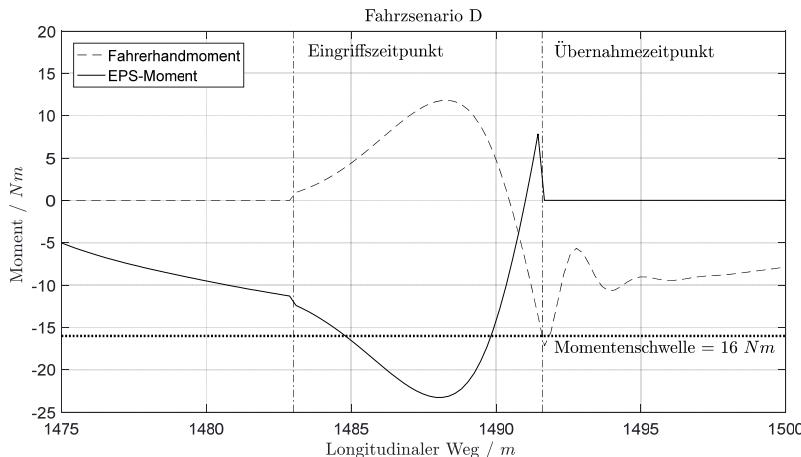


Bild 8: Verlauf des EPS- und Fahrerhandmoments mit Eingriffsassistenten und einem Schwellwert von 16 Nm

In Tabelle 2 wird die Fahrleistung des Fahrers mit und ohne Eingriffsassistenten anhand der prozentualen Abweichung des lateralen Weges  $\Delta y_{mit/ohne}$  und der Querbeschleunigung  $\Delta a_{y,mit/ohne}$  verglichen. Dabei ist davon auszugehen, dass das automatisierte System das optimale Ausweichmanöver fährt.

$$\Delta a_{y,mit/ohne} = \frac{|a_{y,mit/ohne} - a_{y,auto}|}{a_{y,auto}}, \quad \Delta y_{mit/ohne} = \frac{|y_{mit/ohne} - y_{auto}|}{y_{auto}}$$

Tabelle 2: Fahrleistungsmaße bei einem Fahrereingriff mit und ohne Assistenten

Szenario	$\Delta a_{y,mit}$	$\Delta a_{y,ohne}$	$\Delta y_{mit}$	$\Delta y_{ohne}$
D	2,16%	28,44%	2,93%	3,58%

Bei dem Vergleich der beiden Fahrleistungsmaßen fällt auf, dass die Abweichung der Querbeschleunigung (26,28 %) signifikant größer ist als die Querabweichung (0,65%). Demnach bewirkt der Assistent eine deutliche Verbesserung auf das Fahrleistungmaß der Querbeschleunigung.

Die Werte der Fahrleistungsmaße zeigen insgesamt auf, dass Fahrereingriffe mit einer assistierten Funktion im Vergleich zu einem nicht unterstützenden Eingriff zu einer geringeren Abweichung vom Optimum führen. Die Ergebnisse der Simulation lassen darauf schließen, dass

eine mögliche Verbesserung der Fahrleistung des Durchschnittsfahrers aus der Probandenstudie erzielt wird, wenn der Fahrer durch eine Assistenzfunktion während des Eingriffes unterstützt wird.

## 7. Zusammenfassung und Ausblick

In diesem Beitrag werden Ergebnisse von Probandenstudien in einem Fahrsimulator zu Fahreingriffen in hochdynamischen, kritischen Fahrsituationen am Beispiel eines Ausweichmanövers gezeigt. Darauf aufbauend wird ein Konzept für einen Eingriffsassistenten vorgestellt und diskutiert.

Die Ergebnisse aus den Probandenstudien zeigen auf, dass es bei einem Eingriff des Fahrers zu sicherheitskritischen Situationen kommt, obwohl die Automation die Fahrsituation sicher bewältigt hätte. Der daraufhin entwickelte Ansatz für einen Eingriffsassistenten wurde mit Hilfe einer Störgrößenaufschaltung realisiert. Hierbei handelt es sich bei dem Fahrerhandmoment um eine Störgröße, die direkt durch eine Vorsteuerung zur Stellgröße aufaddiert wird. Erreicht das Handmoment eine gewisse Schwelle, wird die Automation abgeschaltet und der Fahrer übernimmt die Kontrolle des Fahrzeugs. Um zu bewerten, ob der Eingriffsassistent die Fahrsicherheit erhöht, wurde ein von IPG entwickeltes Fahrermodell so parametriert, dass hiermit das mittlere Fahrerverhalten aus den Probandenversuchen abgebildet werden konnte. Der Eingriffsassistent wurde mit diesem Fahrermodell durch numerische Simulationsstudien bewertet. Es zeigte sich, dass der entwickelte Eingriffsassistent eine Verbesserung der Fahrsicherheit erreicht.

Im vorgestellten Projekt sollen zukünftig weitere Fahrmanöver betrachtet werden, es sollen weitere Ansätze zur Assistenz entwickelt und analysiert werden, und die Ansätze sollen nicht nur in der Simulation, sondern auch im Fahrsimulator und im realen Fahrzeug untersucht und bewertet werden.

## Danksagung

Die Autoren bedanken sich bei Prof. Dr. phil. Manfred Thüring, Fabienne Roche und Sandra Epple für die Durchführung der Probandenstudie. Ohne die Erhebung dieser Daten hätte dieser Beitrag nicht entstehen können.

Die vorgestellte Arbeit entstand im Rahmen des DFG-Forschungsprojektes „Analyse und Unterstützung von Fahreingriffen in dynamischen, kritischen Situationen beim hochautomatisierten Fahren“ (Förderungsprojektnummer: 326727090).

## Literatur

- [1] T. Gasser et al., Rechtsfolgen zunehmender Fahrzeugautomatisierung, Bergisch Gladbach, Bundesanstalt für Straßenwesen (Berichte der Bundesanstalt für Straßenwesen, Unterreihe „Fahrzeugsicherheit“, Heft F 83, Januar 2012)
- [2] VDA Magazin, Automatisierung - Von Fahrerassistenzsystemen zum automatisierten Fahren, September 2015
- [3] Gutachten des wissenschaftlichen Beirats beim Bundesministerium für Verkehr und digitale Infrastruktur, Zeitschrift für Straßenverkehrstechnik, Heft Nr. 8 u. Heft Nr. 9, April 2017
- [4] S. Brandenburg et al., Kognitionspsychologische Erkenntnisse zum hochautomatisierten Fahren – eine Übersicht, VDI-Berichte Nr. 2312, November 2017
- [5] O. Schädler, Experimentelle Bewertung der Beherrschbarkeit von interagierenden Fahrerassistenzsystemen beim Führen von Kraftfahrzeugen, Verlag Dr. Hut, 2017
- [6] C. Rathgeber, Trajektorienplanung und –folgeregelung für assistiertes bis hochautomatisiertes Fahren, Dissertation, Technische Universität Berlin, Februar 2016
- [7] M. Walter, Kooperative Fahrzeugführungsregelung für assistiertes bis hochautomatisiertes Fahren, Dissertation, Technische Universität Berlin, 2017
- [8] C. Schmidt, Fahrstrategien zur Unfallvermeidung im Straßenverkehr für Einzel- und Mehrobjektszenarien, Dissertation, Karlsruher Institut für Technologie, Juli 2013
- [9] D. Schramm et al., Modellbildung und Simulation der Dynamik von Kraftfahrzeugen, Springer Verlag Berlin Heidelberg, 2010
- [10] S. Zakharian, Automatisierungstechnik Aufgaben: Lineare-, Zweipunkt- und Fuzzy-Regelung, Wiesbaden: Verlag Vieweg, 1998

## Anhang

### A.1. Fahrzeugquerregelung mit Fahrereingriffen

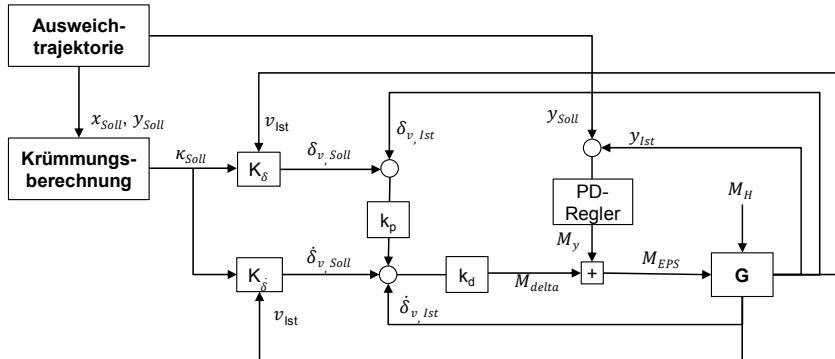


Bild A1: Krümmungsregelung mit unterlagerter, kaskadierter Lenkwinkelregelung

Nach [6] wird  $\kappa_{Soll}$  in einen Solllenkwinkel  $\delta_{v,Soll}$  über  $K_\delta$  umgerechnet.  $K_\delta$  ist das inverse Verhalten von Lenkwinkel zu resultierender Fahrzeugkrümmung und wird aus einem linearen Einspurmodell berechnet. Unter Annahme kleiner Schwimmwinkelgeschwindigkeiten ist die Krümmung definiert als [9]:

$$\kappa = \frac{\dot{\psi}}{v}.$$

Daraus folgt für die stationäre Verstärkung von Lenkwinkel nach Krümmung:

$$K_\delta = \frac{\delta_v}{\kappa} = l \left( 1 + \frac{v^2}{v_{ch}^2} \right).$$

Die Soll-Lenkgeschwindigkeit  $\dot{\delta}_{v,Soll}$  ergibt sich damit zu

$$\dot{\delta}_{v,Soll} = \kappa_{Soll} \cdot K_\delta$$

mit

$$K_\delta = s \cdot K_\delta.$$

Die Differentiation der Verstärkung gilt als nicht realisierbar und ist an dieser Stelle zum Verständnis stellvertretend für die Ableitung aufgeführt. Der Radstand wird als  $l$ , die charakteristische Geschwindigkeit als  $v_{ch}$  und die Gierrate als  $\dot{\psi}$  bezeichnet.

## A.2. Laterales Fahrverhalten

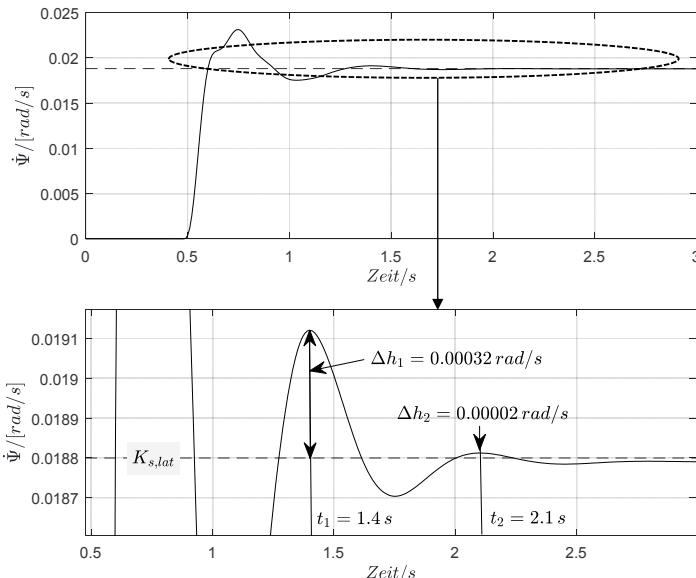


Bild A2: Sprungantwort des Lenkmomentensprungs bei einer Fahrzeuggeschwindigkeit von 80 km/h.  $t_1$  und  $t_2$  sind Zeitpunkte, an denen die Sprungantwort zwei aufeinanderfolgende Maxima aufweist. Die Maxima liegen um  $\Delta h_1$  und  $\Delta h_2$  über dem stationären Endwert  $K_{s,lat}$ .

Das laterale Fahrverhalten des verwendeten Gesamtfahrzeugmodells wird mit einem PT2-Glied approximiert:

$$G_{lat}(s) = \frac{K_{s,lat}}{1 + 2d_{lat}T_{lat}s + T_{lat}^2s^2}$$

Die Berechnung der Systemparameter eines PT2-Gliedes [10] und die dazugehörigen Parameterwerte für eine Fahrzeuggeschwindigkeit von 80 km/h sind in der Tabelle A1 aufgeführt.

Tabelle A1: Parameter des PT2-Glieds zur Approximation der lateralen Regelstrecke

Parameter	Berechnung	$v_{Fzg} = 80 \text{ km/h}$
Verstärkungsfaktor $K_{s,lat}$	$K_{s,lat} = \lim_{t \rightarrow \infty} h(t)$	0,0188
Dämpfungskonstante $d_{lat}$	$d_{lat} = \frac{\ln\left(\frac{\Delta h_1}{\Delta h_2}\right)}{\sqrt{4\pi^2 + \ln^2\left(\frac{\Delta h_1}{\Delta h_2}\right)}}$	0,4037
Zeitkonstante $T_{lat}$	$T_{lat} = \frac{t_2 - t_1}{\sqrt{4\pi^2 + \ln^2\left(\frac{\Delta h_1}{\Delta h_2}\right)}}$	0,1019

### A.3. Parameterwerte der Fahrzeugquerregelung

Tabelle A2: Regelparameter des Querreglers

Regler	Parameter	Parameterwert
Lenkwinkelregelung	$k_p$	10
	$k_d$	18
Querregelung	$k_{p,y}$	0,3
	$T_{d,y}$	3,3

#### A.4. Stabilitätsnachweis der modellierten Fahrzeugquerreglung

Die Ein- und Ausgangsstabilität der modellierten Fahrzeugquerführungsregelung wird durch das Phasenrandkriterium nachgewiesen: „Eine stabile offene Kette, deren Phasengang nur eine Schnittfrequenz  $\omega_S$  besitzt, führt genau dann auf einen E/A-stabilen Regelkreis, wenn der Phasenrand  $\Phi_R$  positiv ist.“

$$\Phi_R = 180^\circ - |\Phi(\omega_S)|$$

Der Spielraum für die Verstärkung der offenen Regelkette bis der Regelkreis instabil wird, heißt Amplitudenrand  $k_R$  und ist wie folgt definiert:

$$k_R = \frac{1}{|G_0(j\omega_{-180^\circ})|}$$

Bild A3 zeigt die offenen Regelkreise und die Übertragungsfunktionen im Frequenzbereich des Fahrzeugquerführungsreglers. Die über Bode-Diagramm (Bild A4, Bild A5, Bild A6) ermittelten Phasenreserven  $\Phi_R$  sind positiv, sodass die E/A-Stabilität des numerisch modellierten Querführungsreglers gegeben ist. Die berechneten Amplitudenränder verdeutlichen, dass die Verstärkungsfaktoren einen beliebigen Wert annehmen können, ohne die Stabilität des Systems zu beeinflussen (Tabelle A3, Tabelle A4)

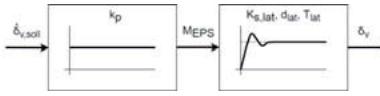
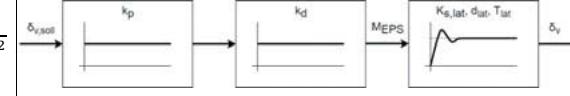
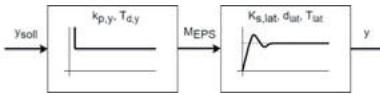
	Übertragungsfunktion	Blockschaltbild
Krümmungsregelung	$\frac{k_d \cdot K_{s,lat}}{1 + 2d_{lat}T_{lat}s + T_{lat}^2s^2}$	
	$\frac{k_p \cdot k_d \cdot K_{s,lat}}{1 + 2d_{lat}T_{lat}s + T_{lat}^2s^2}$	
Querregelung	$\frac{k_{p,y}(T_{d,y}s + 1)K_{s,lat}}{1 + 2d_{lat}T_{lat}s + T_{lat}^2s^2}$	

Bild A3: Offene Regelkreise des Querführungsreglers

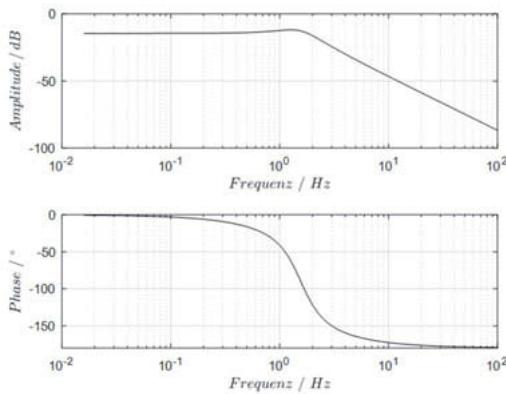


Bild A4: Bode-Diagramm des inneren Regelkreises der Krümmungsregelung bei einer Fahrzeuggeschwindigkeit von 80 km/h

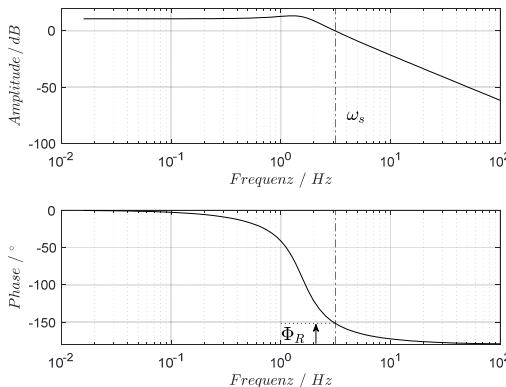


Bild A5: Bode-Diagramm des äußeren Regelkreises der Krümmungsregelung bei einer Fahrzeuggeschwindigkeit von 80 km/h

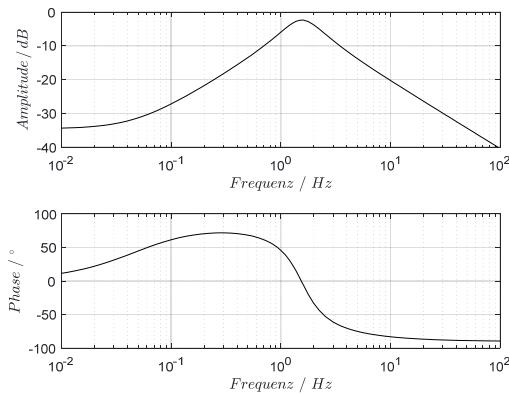


Bild A6: Bode-Diagramm des Regelkreises der lateralen Positionsregelung bei einer Fahrzeuggeschwindigkeit von 80 km/h

Tabelle A3: Übertragungsfunktion  $G_O(s)$  der offenen Regelkreise, Posenreserve  $\Phi_R$  und Amplitudenrand  $k_R$  der Krümmungsregelung

$G_O(s)$	$\Phi_R$	$k_R$
$\frac{0,188}{1 + 0,0823s + 0,01039s^2}$	$\infty$	$\infty$
$\frac{3,384}{1 + 0,0823s + 0,01039s^2}$	28,25 °	$\infty$

Tabelle A4: Übertragungsfunktion  $G_O(s)$  der offenen Regelkreise, Posenreserve  $\Phi_R$  und Amplitudenrand  $k_R$  der lateralen Positionsregelung

$G_O(s)$	$\Phi_R$	$k_R$
$\frac{0,0188 + 0,06267s}{1 + 0,0823s + 0,01039s^2}$	$\infty$	$\infty$

# Relaxed Barrier MPC for Reference Tracking: Theoretical and experimental studies

**Fabian Pfitz, Martin Braun,**

Porsche Engineering Services GmbH, Bietigheim-Bissingen;

**Christian Ebenbauer,**

Institute for Systems Theory and Automatic Control,

University of Stuttgart

## Zusammenfassung

Wir untersuchen das Problem einer Trajektorienfolgeregelung mithilfe eines modellprädiktiven Ansatzes auf Basis von relaxierten Barrierefunktionen. Wir zeigen stabiles Trackingverhalten des geschlossenen Regelkreises für lineare zeitdiskrete Systeme und untersuchen den Einfluss von suboptimalen Lösungen des unterlagerten modellprädiktiven Optimierungsproblems auf die Regelgüte. Des Weiteren testen wir den entwickelten modellprädiktiven Regelungsalgorithmus an einem realen autonom fahrenden Fahrzeug.

## 1 INTRODUCTION

Reference tracking problems, e.g. tracking a temperature profile in a chemical reactor, are important in many practical applications. The objective in a typical reference tracking problem is that the state or a given output of a controlled plant asymptotically tracks a prescribed reference trajectory or reference output. In addition, it is often desired that the tracking error, i.e. the difference between the actual output and the reference output, converges to 0, stays small for all times or stays at least within certain bounds.

There exist many methods to solve a reference tracking problem, see e.g. [2] and [3]. In case of reference tracking problems which involve additional specifications such as constraints, Model Predictive Control (MPC) has turned out to be an effective method to solve such constrained tracking problems. MPC is a model-based control method in which a suitable control input, at each sampling instance, is obtained by solving online an open-loop optimal control problem. Due to the flexibility of optimization problems, many control tasks can be cast as MPC problems. However, MPC suffers from two main disadvantages. On the one hand, the online (real-time) optimization problem imposes high computational effort. On the other hand, due to uncertainties and disturbances, the mismatch between the model-based open-loop optimal control solution and the actual system behaviour may lead to constraint violations or renders the optimization problem infeasible. Several approaches have been proposed in the literature to address these disadvantages. One recent and promising approach is relaxed barrier function MPC (rbMPC), see [6]. By a suitable adaption and reformulation of the open-loop optimal control problem, rbMPC tolerates model uncertainties and disturbances and guarantees at the same time robust stability of the closed loop based on approximate solutions of the open-loop optimal control problem. It has been shown that rbMPC algorithms posses the desirable anytime prop-

erty, i.e. after any number of optimization iterations, even after a single iteration step, the obtained suboptimal solution is sufficient to guarantee stability. Therefore, the computational load of rbMPC is very low and these algorithms are very attractive for practical implements, see [6], [7], [8], [5] for more details. However, rbMPC has not been investigated yet for reference tracking problems. Hence, in this paper we develop a rbMPC formulation for reference tracking problems. In addition, we discuss how so called path following problems can be formulated and implemented with the rbMPC framework. Finally, we evaluate the rbMPC tracking algorithm to the problem setup of autonomous driving.

Throughout the paper, we will make use of the following notation.  $\mathbb{N}_+$ ,  $\mathbb{R}_+$ ,  $\mathbb{R}_{++}$  define sets of nonnegative natural numbers, nonnegative real and strictly positive real numbers. Furthermore  $\mathbb{S}_{++}^n$  and  $\mathbb{S}_{++}^m$  denote the sets of semi-positive definite and positive definite matrices with dimension  $n \in \mathbb{N}_+$ . Furthermore  $I_m \in \mathbb{R}^{m \times m}$  defines an identity matrix with dimension  $m \in \mathbb{N}_+$ . For any matrix  $S \in \mathbb{S}_+$ , the  $S$  weighted Euclidean norm, is defined as  $\|x\|_S := \sqrt{x^\top S x}$ . Moreover  $\mathbb{1}$  defines the all-ones vector of appropriate size, i.e.,  $\mathbb{1} = [1 \ 1 \ \dots \ 1]^\top$ . A continuous function  $\alpha : \mathbb{R}_+ \rightarrow \mathbb{R}_+$  with  $\alpha(0) = 0$  is said to belong to class  $\mathcal{K}$  if it is strictly increasing.  $\alpha \in \mathcal{K}$  belongs to class  $\mathcal{K}_\infty$  if in addition  $\alpha(r) \rightarrow \infty$  as  $r \rightarrow \infty$ .

## 2 PROBLEM SETUP AND PRELIMINARIES

Consider a discrete-time linear system of the form

$$x(k+1) = Ax(k) + Bu(k), \quad x(k_0) = x_0, \quad (1)$$

where  $A \in \mathbb{R}^{n \times n}$  and  $B \in \mathbb{R}^{n \times m}$  represent the system dynamics. Assume that  $(A, B)$  is stabilizable. We impose polytopic state and input constraints

$$\begin{aligned} x(k) \in \mathcal{X} &= \{x \in \mathbb{R}^n : C_x x \leq d_x\} \\ u(k) \in \mathcal{U} &= \{u \in \mathbb{R}^m : C_u u \leq d_u\} \end{aligned} \quad (2)$$

on the system dynamics defined in (1). Notice that  $\mathcal{X}$  and  $\mathcal{U}$  are convex sets which contain the origin in its interior, since  $C_x \in \mathbb{R}^{q_x \times n}$ ,  $C_u \in \mathbb{R}^{q_u \times m}$ ,  $d_x \in \mathbb{R}_{++}^{q_x}$  and  $d_u \in \mathbb{R}_{++}^{q_u}$ . Here  $q_x$  and  $q_u$  represent the number of state and input constraints. The predetermined reference trajectory is defined as

$$\{x_{\text{ref}}(k), u_{\text{ref}}(k)\}_{k=0, \dots, \infty}, \quad (3)$$

where we assume that  $x_{\text{ref}}(N_e)$  and  $u_{\text{ref}}(N_e)$  is constant for some  $k \geq N_e \in \mathbb{N}$ . Furthermore, we assume that the trajectory defined in (3) satisfies

$$x_{\text{ref}}(k+1) = Ax_{\text{ref}}(k) + Bu_{\text{ref}}(k), \quad x_{\text{ref}}(k_0) = x_{\text{ref},0}. \quad (4)$$

We impose tightened polytopic state and input constraints on the trajectory defined in (3) which is defined as  $x_{\text{ref}}(k) \in \mathcal{X}_{\text{ref}} = \{x_{\text{ref}} \in \mathbb{R}^n : C_x x_{\text{ref}} + \kappa_x \leq d_x\}$  and  $u_{\text{ref}}(k) \in \mathcal{U}_{\text{ref}} = \{u_{\text{ref}} \in \mathbb{R}^m : C_u u_{\text{ref}} + \kappa_u \leq d_u\}$ , where  $\kappa_x \in \mathbb{R}_{++}^{q_x}$  and  $\kappa_u \in \mathbb{R}_{++}^{q_u}$ . Notice that the tightening of the polytopic

state and input constraints will be important for the stability proof given in Section 3. Moreover, we introduce the error variables of the state and input  $e_x(k)$  and  $e_u(k)$  as

$$e_x(k) = x(k) - x_{\text{ref}}(k) \quad (5a)$$

$$e_u(k) = u(k) - u_{\text{ref}}(k). \quad (5b)$$

The error dynamics are then given as

$$e_x(k+1) = Ae_x(k) + Be_u(k), \quad (6)$$

where (6) has to satisfy the error polytopic state and input constraints

$$e_x(k) \in \mathcal{E}_x(k) = \{e_x \in \mathbb{R}^n : C_x e_x \leq \tilde{d}_x(k)\} \quad (7a)$$

$$e_u(k) \in \mathcal{E}_u(k) = \{e_u \in \mathbb{R}^m : C_u e_u \leq \tilde{d}_u(k)\}, \quad (7b)$$

With the help of (5a), the reference tracking problem can be formulated as a setpoint stabilization problem of the error, i.e. to goal is to achieve  $\lim_{k \rightarrow \infty} e_x(k) = 0$ , see [4].

Reference tracking problems and MPC has been addressed in several publications, see e.g. [15], [13], [12], [2] and [1]. Due to the attractive properties of rbMPC, we aim in this work to solve the reference tracking problem by means of a relaxed barrier functions-based MPC formulation. In a general MPC scheme, an open-loop optimal control problem is solved at every time step (sampling instance)  $k$ . For the given reference tracking problem, the open-loop optimal control problem can be formulated as follows

$$\begin{aligned} J_N^*(e_x(k), k) = \min & \sum_{j=0}^{N-1} l(e_{x,j}, e_{u,j}) + F(e_{x,N}) \\ \text{s.t. } & e_{x,j+1} = Ae_{x,j} + Be_{u,j}, \quad e_{x,0} = e_x(k), \\ & e_{x,j} \in \mathcal{E}_{x,j}(k), j = 0, \dots, N-1 \\ & e_{u,j} \in \mathcal{E}_{u,j}(k), j = 0, \dots, N-1 \end{aligned} \quad (8)$$

where  $e_x(k) = x(k) - x_{\text{ref}}(k)$  denotes the current measured state error. The optimal open-loop input sequence  $e_u$  over the prediction horizon  $N \in \mathbb{N}_+$  is defined as  $e_u^*(e_x(k)) = \{e_{u,0}^*(e_x(k)), \dots, e_{u,N-1}^*(e_x(k))\}$ . Notice that the subindices  $e_{x,j}$ ,  $e_{u,j}$  are used for open-loop predictions and  $e_x(k)$ ,  $e_u(k)$  denote the actual state error trajectory and the input error.  $\mathcal{E}_x(k)$ ,  $\mathcal{E}_u(k)$  define time-varying polytopes depending on the reference state and input trajectories. The terminal cost  $F : \mathbb{R}^n \rightarrow \mathbb{R}_+$  is defined as  $F(e_{x,N}) = \|e_{x,N}\|_P^2$ , where  $P \in \mathbb{S}_{++}$  is designed in Section 3 such that stability of the proposed MPC scheme is guaranteed. The stage cost  $l : \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}_+$  is defined as

$$l(e_{x,j}, e_{u,j}) := \|e_{x,j}\|_Q^2 + \|e_{u,j}\|_R^2, \quad (9)$$

where  $Q \in \mathbb{S}_{++}^n$  and  $R \in \mathbb{S}_+^m$  are suitable chosen tuning matrices. Notice that we do not use any terminal set in our MPC formulation. As usual, the resulting feedback of the proposed MPC scheme

is obtained from the solution of the open-loop optimal control problem based on the current error state  $e_x(k)$  and the current timestep  $k$ . In particular, only the first element of the optimal input error sequence  $e_u^*(e_x(k)) = \{e_{u,0}^*(e_x(k)) \dots e_{u,N-1}^*(e_x(k))\}$  is applied to the system dynamics. The resulting closed loop system arises to

$$x_{k+1} = Ax_k + B(e_{u,0}^*(e_x(k)) + u_{\text{ref}}(k)). \quad (10)$$

In the following, the open-loop optimal control problem defined in (8) is reformulated in terms relaxed barrier functions. The basic idea is to eliminate the constraints and to introduce relaxed barrier functions as penalty terms into the cost functional, see [7]. Due to the use of relaxed barrier functions, recursive feasibility and the called anytime property can be guaranteed by design under rather mild assumptions, see [6]. It is worthwhile to point out that, despite the use of relaxed barrier functions, exact constraint satisfaction can be guaranteed, see [6, Corollary 3.2]. For the generalization of rbMPC to time-varying constraints, we introduce the following definitions.

**Definition 1.** Let  $\mathcal{P}^\circ = \{z \in \mathbb{R}^r : Cz \leq d(k)\}$  with  $C \in \mathbb{R}^{q \times r}$ ,  $d(k) \in \mathbb{R}_{++}^q$  be a polytopic set containing the origin and let  $\bar{B} : \mathcal{P}^\circ \times \mathbb{R}_+ \rightarrow \mathbb{R}$ ,  $\bar{B}(z, k) = \sum_{i=1}^q \bar{B}_i(z, k)$  with  $\bar{B}_i(z, k) = -\ln(-C^i z + d^i(k))$  be the corresponding logarithmic barrier function. Then, the function  $B_G : \mathcal{P}^\circ \times \mathbb{R}_+ \rightarrow \mathbb{R}_+$  with

$$B_G(z, k) = \bar{B}(z, k) - \bar{B}(0, k) - [\nabla \bar{B}(0, k)]^\top z \quad (11)$$

defines the gradient recentered logarithmic barrier function for the polytopic set  $\mathcal{P}^\circ$ .

Moreover, consider a scalar  $\delta \in \mathbb{R}_{++}$  called the relaxation parameter with  $\delta \mathbb{1} \leq d(k)$  and let  $\beta(z; \delta) : (-\infty, \delta] \rightarrow \mathbb{R}$  be a strictly monotone and continuously differentiable function that satisfies  $\beta(\delta; \delta) = -\ln(\delta)$  as well as  $\lim_{z \rightarrow -\infty} \beta(z; \delta) = \infty$ . Then, we call  $\hat{B} : \mathbb{R} \times \mathbb{R}_+ \rightarrow \mathbb{R}$  defined as

$$\hat{B}(z, k) = \begin{cases} B_G(z, k) & z > \delta \\ \beta(z; \delta) & z \leq \delta \end{cases} \quad (12)$$

the relaxed logarithmic barrier function for the set  $\mathbb{R}_+$  and refer to the function  $\beta(z; \delta)$  as the relaxing function.

In particular, we will make use of the following polynomial relaxing function

$$\beta_k(z; \delta) = \frac{i-1}{i} \left[ \left( \frac{z - i\delta}{(i-1)\delta} \right)^i - 1 \right] - \ln(\delta), \quad (13)$$

where  $i > 1$  is an even integer. In the remainder, we will choose  $i = 2$  as suggested by [7] and [10]. With Definition 1, the open-loop optimal control problem (8) of the rbMPC tracking scheme can be formulated as

$$\begin{aligned} \hat{J}_N^*(e_x(k), k) = \min & \sum_{j=0}^{N-1} \hat{l}(e_{x,j}, e_{u,j}, k) + F(e_{x,N}) \\ \text{s.t.} & e_{x,j+1} = Ae_{x,j} + Be_{u,j}, \quad e_{x,0} = e_x(k), \end{aligned} \quad (14)$$

where the terminal cost  $F : \mathbb{R}^n \rightarrow \mathbb{R}_{++}$  is defined in (8) as  $F(e_{x,N}) = \|e_{x,N}\|_P^2$ . The stage cost  $\hat{l} : \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R} \rightarrow \mathbb{R}_{++}$  is defined as

$$\hat{l}(e_{x,j}, e_{u,j}, k) := \|e_{x,j}\|_Q^2 + \|e_{u,j}\|_R^2 + \epsilon \hat{B}(e_{x,j}, e_{u,j}, k), \quad (15)$$

where  $\hat{B}(e_{x,j}, e_{u,j}, k) = \hat{B}_x(e_{x,j}, k) + \hat{B}_u(e_{u,j}, k)$  is the gradient recentered relaxed logarithmic barrier function with respect to the polytopic sets (2) and  $\epsilon \in \mathbb{R}_{++}$ . Notice that the  $(\hat{\cdot})$  - symbol indicates the use of relaxed barrier functions.

### 3 MAIN RESULT

In the following, we prove stability of the error dynamics of the closed-loop system defined in (10). For the stability proof, it is important that the gradient recentered relaxed barrier function  $\hat{B}(e_{x,j}, e_{u,j}, k)$  can be quadratically upper bounded uniformly in  $k$ . This is shown in the following Lemma.

**Lemma 1.** *Let  $(A, B)$  be stabilizable and let  $K \in \mathbb{R}^{m \times n}$  be such that the absolute values of all eigenvalues of  $A + BK$  are strictly less than one. Furthermore, let  $\hat{B}_x(e_{x,j}, k)$  and  $\hat{B}_u(e_{u,j}, k)$  be defined according to Definition 1 and let  $\beta_2(z; \delta)$  be defined as in (13). Consider  $\hat{B}(e_{x,j}, k) = \hat{B}_x(e_{x,j}, k) + \hat{B}_u(K e_{x,j}, k)$  for a given  $\delta \in \mathbb{R}_{++}$ . Then, it holds that*

$$\forall e_j \in \mathbb{R}^n, \forall \tilde{d}(k) > \delta \mathbb{1} : \quad \hat{B}(e_j, k) \leq e_j^\top M e_j, \quad (16)$$

with  $\tilde{d}(k) = [\tilde{d}_x(k), \tilde{d}_u(k)]^\top$ ,  $e_j = [e_{x,j}, e_{u,j}]^\top$  and  $M = M_x + K^\top M_u K$ , where the matrices  $M_x \in \mathbb{R}^{n \times n}$  and  $M_u \in \mathbb{R}^{m \times m}$  are defined as  $M_x := \frac{1}{2\delta^2} C_x^\top C_x$  and  $M_u := \frac{1}{2\delta^2} C_u^\top C_u$  respectively, with  $C_u, C_x$  defined according to (2).

Notice that the gradient recentered relaxed barrier function  $\hat{B}(e, k)$  depends on  $\tilde{d}(k)$ , see Definition 1. By choosing the tightened reference constraints defined in Section 2 with  $0 < \delta < \min(\kappa_x, \kappa_u)$ ,  $\tilde{d}(k)$  fulfills condition (16) in Lemma 1.

**Theorem 1.** *The error dynamics (6) associated to the closed loop system (10) (14) is uniformly globally asymptotic stable.*

*Proof Outline:* Due to space limitations, we just outline the proof. It is well known that a system  $x(k+1) = f(x(k), k)$  is uniformly globally asymptotic stable, if there exists a continuous Lyapunov function  $V : \mathbb{R}^n \times \mathbb{N}_+ \rightarrow \mathbb{R}$ , such that

$$\alpha_1(x) \leq V(x, k) \leq \alpha_2(x) \quad (17a)$$

$$V(f(k, x), k+1) - V(x, k) \leq -\alpha_3(x) \quad (17b)$$

holds for all  $k \in \mathbb{N}_+$ ,  $x \in \mathbb{R}^n$ , where  $\alpha_1, \alpha_2 \in \mathcal{K}_\infty$  and  $\alpha_3$  positive definite. We choose  $\hat{J}_N^*(e_{x,0}, k)$  as a Lyapunov function with  $e_{x,0} = e_x(k)$  the current error state and  $k$  the current sampling instance. To fulfill condition (17a), we have to derive an lower and upper bound  $\alpha_1(x)$ ,  $\alpha_2(x)$  which are independent of the sample instance  $k$ . Observe that  $\hat{J}_N^*(e_{x,0}, k)$  as defined in (14) depends on the sampling instance  $k$ , due to the recentered relaxed barrier function  $\hat{B}(e_{x,j}, e_{u,j}, k)$ . Using the inequality (16) of Lemma 1, we can derive an uniform global upper bound which belongs to the class

$\mathcal{K}_\infty$ . Moreover, we can derive an lower bound independently of the sampling instance  $k$  that belongs to the class  $\mathcal{K}_\infty$  by using

$$e_x(k)^\top Q e_x(k) \leq J_N^*(e_x(k), k), \quad (18)$$

with  $Q \in \mathbb{S}_{++}^n$ . To fulfill condition (17b), we choose the terminal cost as

$$F(e_{x,N}) = e_{x,N}^\top P e_{x,N}, \quad P \in \mathbb{S}_{++}, \quad (19)$$

where  $P$  is the solution of the modified discrete-time algebraic Riccati equation. In particular, we have

$$P = A_k^\top P A_k + K^\top (R + \epsilon M_u) K + Q + \epsilon M_x \quad (20a)$$

$$K = -(R + B^\top P B + \epsilon M_u)^{-1} B^\top P A, \quad (20b)$$

where  $A_k = A + B K$  (see also [6]) and  $M_x, M_u$  is defined according to Lemma 1. Next we consider

$$\hat{J}^*(e_{x,0}^+(e_{x,0}), k+1) - \hat{J}^*(e_{x,0}, k), \quad (21)$$

where  $\hat{J}^*(e_{x,0}^+(e_{x,0}), k+1)$  is the suboptimal cost at the successor error state  $e_{x,0}^+ = e_{x,1}^*$  and the sampling instance  $k+1$ .  $\hat{J}^*(e_{x,0}, k)$  defines the optimal cost at the error state  $e_{x,0}$  and sampling instance  $k$ . Notice that, for any  $e_{x,0} \in \mathbb{R}^n$  and  $k \in \mathbb{R}$ , there exist optimal input and state error sequences  $e_u^*(e_{x,0}) = \{e_{u,0}^*, \dots, e_{u,N-1}^*\}$  and  $e_x^*(e_{x,0}) = \{e_{x,0}^*, \dots, e_{x,N}^*\}$ . The suboptimal input and state error sequences are obtained with (20b) to  $e_u^+(e_{x,0}) = \{e_{u,1}^*, \dots, e_{u,N-1}^*, K e_{x,N}^*\}$  and  $e_x^+(e_{x,0}) = \{e_{x,1}^*, \dots, e_{x,N}^*, (A + B K) e_{x,N}^*\}$ . The corresponding cost of the suboptimal input and state error sequences holds to  $\hat{J}_N(e_u^+(e_{x,0}), e_{x,0}^+, k+1)$ . By simply using the fact that  $\hat{J}_N(e_u^+(e_{x,0}), e_{x,0}^+, k+1)$  is suboptimal the inequality

$$\Delta \hat{J}_N^*(e_u^+(e_{x,0}), e_{x,0}, e_{x,0}^+, k) \leq \hat{J}_N(e_u^+(e_{x,0}), e_{x,0}^+, k+1) - \hat{J}_N^*(e_{x,0}, k) \quad (22a)$$

holds, where  $\Delta \hat{J}_N^*(e_u^+(e_{x,0}), e_{x,0}, e_{x,0}^+, k) = \hat{J}_N(e_u^+(e_{x,0}), e_{x,0}^+, k+1) - \hat{J}_N^*(e_{x,0}, k) = \sum_{k=1}^N \hat{l}(e_{x,k}^+, e_{u,k}^+, k+1) + e_{x,N+1}^{+\top} P e_{x,N+1}^+ - \sum_{k=0}^{N-1} \hat{l}(e_{x,k}^*, e_{u,k}^*, k) + e_{x,N}^{*\top} P e_{x,N}^*$ . Now, we can apply the results of Lemma 1 to uniformly globally upper bound  $\hat{l}(e_{x,N}^+, e_{u,N}^+, k+1) = \|e_{x,N}^*\|_Q^2 + \|K e_{x,N}^*\|_R^2 + \epsilon \hat{B}_K(e_{x,N}^*)$ , where  $\hat{B}(e_{x,N}^*, k) = \hat{B}_x(e_{x,N}^*, k) + \hat{B}_u(K e_{x,N}^*, k)$  which leads to

$$\hat{l}(e_{x,N}^+, e_{u,N}^+, k+1) \leq \|e_{x,N}^*\|_Q^2 + \|K e_{x,N}^*\|_R^2 + \epsilon e_{x,N}^{*\top} (M_x + K^\top M_u K) e_{x,N}^*. \quad (23)$$

With the definition of  $e_{x,N+1}^{*\top} P e_{x,N+1}^* = \|(A + B K) e_{x,N}^*\|_P^2$ , we end up

$$\Delta \hat{J}_N^*(e_u^+(e_{x,0}), e_{x,0}, e_{x,0}^+, k) \leq -\hat{l}(e_{x,0}, e_{u,0}, k) + e_{x,N}^{*\top} P_0 e_{x,N}^*, \quad (24)$$

where  $P_0 = (A_k^\top P A_k + K^\top (R + \epsilon M_u) K + Q + \epsilon M_x - P)$ . By definition of the modified Riccati equation defined in (20a)  $P_k$  equals to 0. Using the inequality  $\hat{l}(e_{x,0}, e_{u,0}, k) \geq l(e_{x,0}, e_{u,0})$  with  $l(e_{x,0}, e_{u,0}) := \|e_{x,0}^*\|_Q^2 + \|e_{u,0}^*\|_R^2$ , we get

$$\Delta \hat{J}_N^*(e_{x,0}^+(e_{u,0}), e_{x,0}, e_{x,0}^+, k) \leq -l(e_{x,0}, e_{u,0}), \quad (25)$$

where  $l(e_{x,0}, e_{u,0})$  is positive definite which fulfills the condition (17b) of Theorem 1. Hence, we have shown global asymptotic stability of the error dynamics of the corresponding rbMPC tracking formulation.  $\square$

#### 4 NUMERICAL EXAMPLE

In the following, we apply the rbMPC tracking algorithm to a simple discrete-time double integrator system. The system dynamics are given by

$$x(k+1) = \begin{bmatrix} 1 & h \\ 0 & 1 \end{bmatrix} x(k) + \begin{bmatrix} h^2 \\ h \end{bmatrix} u(k), \quad x(k_0) = x_0, \quad (26)$$

where  $h = 0.1$  denotes the stepsize. The polytopic state and input constraints of the system dynamics are  $\mathcal{U} = \{u \in \mathbb{R} : -2 \leq u \leq 2\}$  and  $\mathcal{X} = \{x \in \mathbb{R}^2 : -1 \leq x_1 \leq 1, -4\frac{\pi}{10} \leq x_2 \leq 4\frac{\pi}{10}\}$ . We assume that the reference trajectory satisfies the dynamics (26). We impose tightened polytopic state and input constraints with  $\kappa_u = 0.2$  and  $\kappa_x = \begin{bmatrix} 0.05 & 0.025 \end{bmatrix}^\top$ . The relaxation parameter of the relaxed barrier functions is  $\delta = 1e^{-3}$  which fulfills  $\delta \leq \min(\kappa_x, \kappa_u)$  and the weighting parameter is set to  $\epsilon = 1e^{-7}$ . The prediction horizon of the open-loop optimal control problem is chosen to  $N = 20$ . The weighting matrices of the open-loop optimal control problem are denoted as  $Q = \begin{bmatrix} 2 \cdot 10^2 & 0 \\ 0 & 1 \end{bmatrix}$  and  $R = 1$ . The time  $t_k$  is defined as  $t_k = kh$ . The rbMPC tracking algorithm is formulated in the sparse formulation, see [6, p. 132 f.] with the shift-warmstart defined in [6, p.126 f.]. The simulation results were carried out with an Intel i5-7300 vPro processor (12.51 GFLOPS).

The Subfigures 2.1 and 2.2 show the control inputs as well as the state trajectories of the closed-loop system with respect to different initial conditions  $x(0) = x_{0,i}, i = 1, 2, 3$ . The tuning parameters  $\epsilon$  and  $\delta$  are chosen such that the input and state constraints are not violated. As mentioned in Section 2, a rbMPC setpoint stabilization algorithm can be derived that posses the so called anytime property. Similarly, an anytime iteration scheme can be formulated for the tracking problem. Due to space limitations, we refer to [6] for details.

Looking at the Figures 2.1 - 2.3, we can conclude that the proposed rbMPC tracking algorithm performs very well with low computational effort, see Figure 2.3. The averaged tracking behaviour

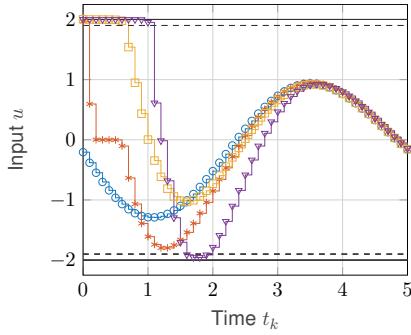


Fig. 1.1: Control input for different initial conditions  $x(0) = x_{0,i}$ ,  $i = 1, 2, 3$  depicted as (—\*—), (—□—) and (—△—). The reference control input is portrayed as (—○—).

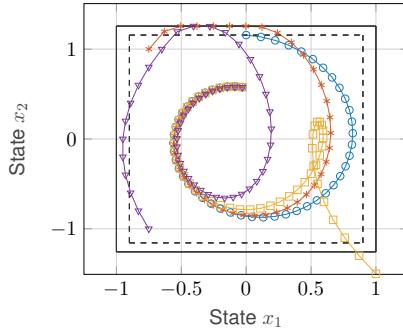


Fig. 1.2: State trajectories of the closed-loop system for different initial conditions  $x(0) = x_{0,i}$ ,  $i = 1, 2, 3$  depicted as (—\*—), (—□—), (—△—) and the reference trajectory shown as (—○—).

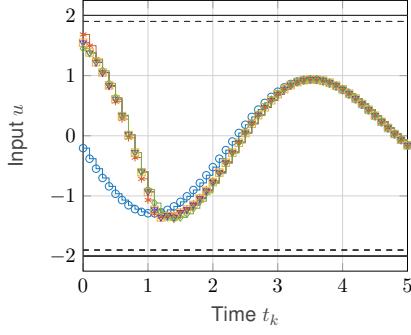


Fig. 2.1: Averaged control input over  $n = 200$  random initial conditions  $x(0) = x_{0,i}$ ,  $i = 1, \dots, 200$  at different number of iterations  $i_T(k) = 1$  (—\*—),  $i_T(k) = 5$  (—□—),  $i_T(k) = 10$  (—△—) and fully optimized (—○—). The reference control input is portrayed as (—○—).

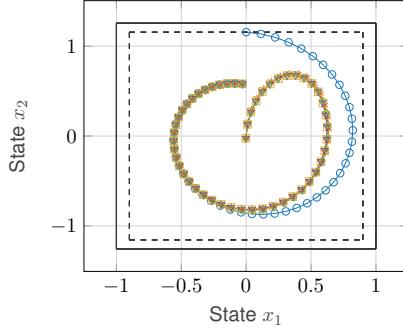


Fig. 2.2: Averaged state trajectories of the closed-loop system over  $n = 200$  random initial conditions  $x(0) = x_{0,i}$ ,  $i = 1, \dots, 200$  at different number of iterations  $i_T(k) = 1$  (—\*—),  $i_T(k) = 5$  (—□—),  $i_T(k) = 10$  (—△—) and fully optimized (—○—). The reference trajectory is portrayed as (—○—).

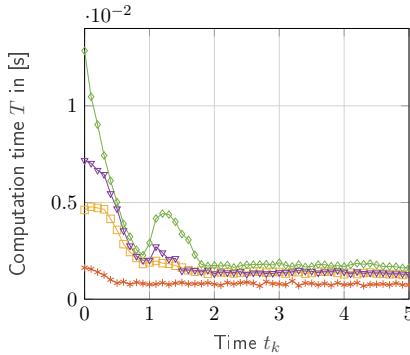


Fig. 2.3: Averaged computation time over  $n = 200$  random initial conditions  $x(0) = x_{0,i}$ ,  $i = 1, \dots, 200$  for different number of optimization steps  $i_T(k) = 1$  (—\*—),  $i_T(k) = 5$  (—□—),  $i_T(k) = 10$  (—△—) and fully optimized (—◇—).

between the exact optimal solution and the solution with a single optimization step is nearly the same, see Figure 2.2.

## 5 AUTONOMOUS DRIVING

In the following, we apply the rbMPC tracking algorithm to the problem of autonomous driving. We adapt the rbMPC tracking algorithm so that it can be also used for a path following problem, see [2], [4] and [16]. We denote the system state variable with  $\xi : \mathbb{N} \rightarrow \mathbb{R}^n$  and  $(x(k), y(k)) \in \mathbb{R}^2$  now refers to the coordinates of the vehicle's center of mass. Similar to the reference tracking problem defined in Section 2, we like to follow a predescribed path that is defined as

$$\{\xi_{\text{ref}}(\theta_k), u_{\text{ref}}(\theta_k)\}_{k=0 \dots \infty}, \quad (27)$$

where  $\xi_{\text{ref}}(N_e)$  and  $u_{\text{ref}}(N_e)$  are constant for some  $\theta_k \geq N_e \in \mathbb{N}$  and  $\theta_k \in \mathbb{N}$  refers to the so called path variable, see [16]. We assume that the predescribed path (27) follows a dynamical vehicle model, see e.g. [11]. Notice that the reference state  $\xi_{\text{ref}}(\theta_k)$  contains at least  $x_{\text{ref}}(\theta_k), y_{\text{ref}}(\theta_k)$  and  $o_{\text{ref}}(\theta_k)$ . Compared to the problem setup of reference tracking defined in Section 2, we have an additional degree of freedom by choosing  $\theta_k = r(k)$ , where  $r : \mathbb{N} \rightarrow \mathbb{N}$  refers to the update law of the path variable. Similar to the reference tracking problem defined in Section 2, the goal is to achieve  $\lim_{r(k) \rightarrow \infty} e_{\xi}(k) = 0$ , where  $e_{\xi}(k) = \xi(k) - \xi_{\text{ref}}(r(k))$  and to design an update law  $r(k)$  that is monotonic increasing and fulfills  $\lim_{k \rightarrow \infty} r(k) = \infty$ . Similar to the notion in [9] and [3], we design the

update law such that  $r(k) = \arg \min_r \|x(k) - x_{\text{ref}}(r)\|_2^2 + \|y(k) - y_{\text{ref}}(r)\|_2^2$  subject to  $\lim_{k \rightarrow \infty} r(k) = \infty$  and  $r(k)$  monotonic increasing. The position and reference position of the vehicle is defined as  $p(k) := \{x(k), y(k)\} \subseteq \mathbb{R}^2$  and  $p_{\text{ref}}(r(k)) := \{x_{\text{ref}}(r(k)), y_{\text{ref}}(r(k))\} \subseteq \mathbb{R}^2$ , respectively. Moreover, the tangential vector at the current reference point  $p_{\text{ref}}(r(k))$  is defined as  $o_{\text{ref}}(r(k))$ .

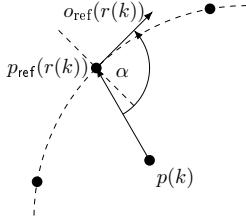


Fig. 3.1: No update  $r(k+1) = r(k)$  at sample instance  $k$  is performed if the angle between the tangential vector  $o_{\text{ref}}(r(k))$  and the vector  $(p_{\text{ref}}(r(k)) - p(k))$  is bigger than  $90^\circ$ .

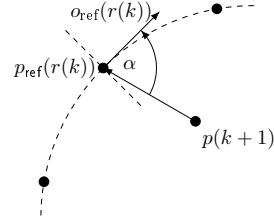


Fig. 3.2: An update  $r(k+1) = r(k) + 1$  at sample instance  $k+1$  is performed as the angle between the tangential vector  $o_{\text{ref}}(r(k))$  and the vector  $(p_{\text{ref}}(r(k)) - p(k))$  is less or equal than  $90^\circ$ .

The rbMPC tracking open-loop optimal control problem is given by

$$\hat{J}_N^*(e_\xi(r(k)), k) = \min \sum_{j=0}^{N-1} \hat{l}(e_{\xi,j}, e_{u,j}, k) + e_{\xi,N}^\top P e_{\xi,N} \quad (28a)$$

$$\text{s.t. } e_{\xi,j+1} = A_k e_{\xi,j} + B_k e_{u,j}, \quad e_{\xi,0} = e_\xi(r(k)), \quad (28b)$$

where  $e_\xi(r(k)) = \xi(k) - \xi_{\text{ref}}(r(k))$ . The matrices  $A_k$  and  $B_k$  are defined as

$$A_k = \frac{\partial f}{\partial \xi} \Big|_{\xi_{\text{ref}}(r(k)), u_{\text{ref}}(r(k))}, \quad B_k = \frac{\partial f}{\partial u} \Big|_{\xi_{\text{ref}}(r(k)), u_{\text{ref}}(r(k))}, \quad (29)$$

where  $f : \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}^n$  describes a kinematic car model, see [11]. In the following, we show experimental results of a self-driving car. The rbMPC tracking algorithm is formulated in the sparse formulation, see [6, p. 132 f.] with a shifted warmstart solution, see [6, p.126 f.]. For the implementation at the real vehicle, the following simplifications were made. The reference inputs are chosen to be  $u_{\text{ref}}(k) = 0$  for all  $k$  and the terminal cost matrix  $P$  is chosen to be the state weight matrix  $Q \in \mathbb{R}^{n \times n}$ . Moreover only input constraints are considered. Notice that with the given simplifications, stability is in general not guaranteed. The following experimental results show evaluations with respect to the path following behaviour and computation times of the rbMPC tracking algorithm.

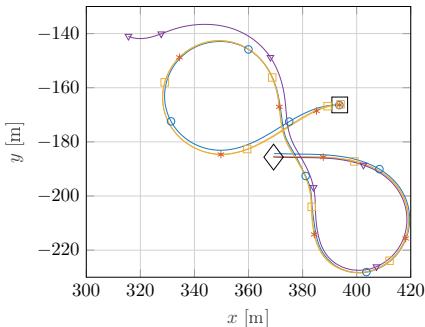


Fig. 4.1: This figure shows the result of the simplified rbMPC tracking algorithm to a self driving car. The starting point of the pre-defined path is marked with (□). The endpoint is marked with (◇). It consists of three test drives compared to the pre-defined path  $\{x_{ref}(\theta_k), y_{ref}(\theta_k)\}_{k=0 \dots \infty}$  depicted as (—○—). The first two testdrives deal with small initial error portrayed as (—\*—) and (—□—). (—\*—) shows the behaviour of the full optimized rbMPC tracking algorithm, where full optimization means that the optimization steps are performed until a stopping criteria is reached, see [6]. (—□—) displays the rbMPC tracking algorithm wherein a single optimization step is performed. The third testdrive deals with the full optimized rbMPC tracking algorithm with a large initial error depicted as (—△—). The rbMPC tracking algorithm with a single optimization step could not be used because of constraint violation.

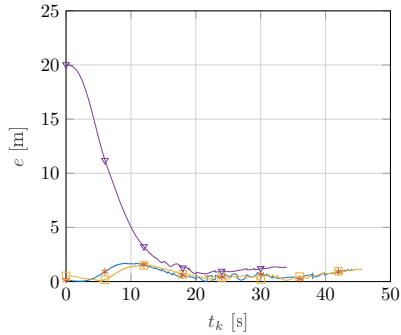


Fig. 4.2: This figure shows the corresponding lateral error with  $e(t_k) = \sqrt{(x(t_k) - x_{ref}(t_k))^2 + (y(t_k) - y_{ref}(t_k))^2}$  to the maneuvers (—\*—), (—□—), (—△—) defined in 4.1

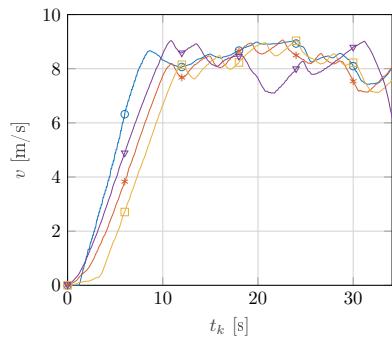


Fig. 4.3: This figure shows the velocities of the testdrives (—\*—), (—□—), (—△—), see Figure 4.1.

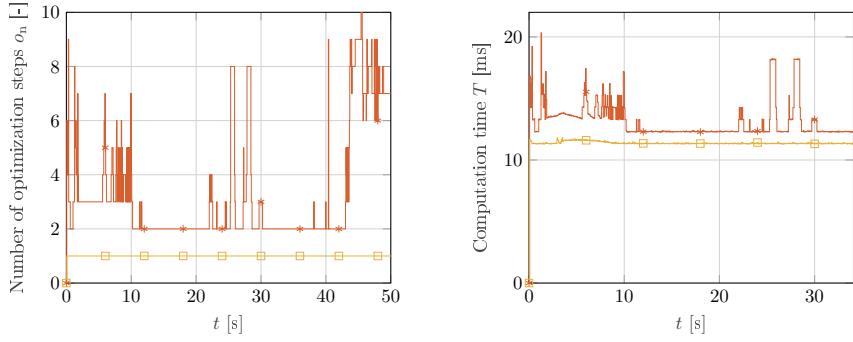


Fig. 5: These figures show the computation times  $T$  and the number of optimization steps  $o_n$  with respect to the full optimized rbMPC tracking algorithm (—●—) and the rbMPC tracking algorithm where only a single optimization step (—□—) is performed concerning the maneuver defined in Subfigure 4.1. Considering the figures above, it can be observed that the number of optimization steps linearly depends on the needed computation time. The linear curve results in  $t = 1\text{ms} \cdot o_n + 10.3\text{ms}$ . This means that every optimization step needs in average 1ms. The computation of the problem matrices of the sparse problem formulation needs 10.3ms.

The application to a self-driving car shows that the proposed rbMPC tracking algorithm performs also well in a path following problem setup, see Figure 4.1. The rbMPC tracking algorithm with a single optimization step results more or less in the same tracking behaviour as with the exact solution if the initial error from the prescribed path is small enough, see Figure 4.2. Further experimental data can be found in [14]. Notice that the real-time computations were done data on an Intel Core i7-3555LE (40 GFLOPS).

## 6 CONCLUSION AND FUTURE WORK

We have provided a stability proof for the error dynamics of the closed-loop system for the proposed rbMPC tracking algorithm under time-varying polytopic constraints. Further, we have applied the proposed rbMPC tracking algorithm to the example of a discrete-time double integrator and to a real-world path following autonomous driving problem. We have evaluated the performance of the rbMPC tracking algorithm with respect to the tracking behaviour and the computational complexity, respectively. We observed that the rbMPC tracking algorithm with only a few optimization steps has satisfactory performance. Several improvements of the rbMPC tracking algorithm are desirable.

For example, the error in the velocity signal needs to be reduced. The velocity error originates from implementing a simplified version of the rbMPC tracking algorithm, where  $u_{\text{ref}}(r(k)) = 0$  for all  $k$ . By a suitable chosen  $u_{\text{ref}}(r(k))$  the error in the velocity signal can be reduced. Moreover, the maximum tracking error of about 1.7m which originates from badly tuned low-level controllers as well as from applying a linear rbMPC tracking algorithm to a nonlinear model. One idea is to utilize a disturbance observer that is used to predict the disturbances and the model mismatch. Finally, the computation of the problem matrices in the sparse formulation can be made more efficient by exploiting the sparsity of the problem matrices.

## References

- [1] A. Aguiar and J. Hespanha. Trajectory-tracking and path-following of underactuated autonomous vehicles with parametric modeling uncertainty. *IEEE Transactions on Automatic Control*, 52:1362–1379, 2007.
- [2] A. Aguiar, J. Hespanha, and P. Kokotović. Path-following for nonminimum phase systems removes performance limitations. *IEEE Transactions on Automatic Control*, 50:234–239, 2005.
- [3] P. Encarnacao and A. Pascoal. Combined trajectory tracking and path following an and application to the coordinated control of autonomous marine craft. *IEEE Conference on Decision and Control*, 1:964–969, 2001.
- [4] T. Faulwasser, B. Kern, and R. Findeisen. Model predictive path-following for constrained nonlinear systems. *IEEE Conference on Decision and Control*, 48:8642–8647, 2009.
- [5] C. Feller and C. Ebenbauer. A stabilizing iteration scheme for model predictive control based on relaxed barrier functions. *Automatica*, 80:328–339, 2016.
- [6] C. Feller and C. Ebenbauer. *Relaxed Barrier Function Based Model Predictive Control*. Logos Verlag Berlin, 2017.
- [7] C. Feller and C. Ebenbauer. Relaxed logarithmic barrier function based model predictive control of linear systems. *IEEE Transactions on Automatic Control*, 62:1223–1238, 2017.
- [8] C. Feller and C. Ebenbauer. Sparsity-exploiting anytime algorithms for model predictive control: A relaxed barrier approach. *IEEE Transactions and Control Systems Technology*, 26:1–11, 2018.
- [9] J. Hauser and R. Hindman. Maneuver regulation from trajectory tracking: Feedback linearizable systems. *IFAC Nonlinear Control Systems Design*, 28:595–600, 1995.

- [10] J. Hauser and A. Saccon. A barrier function method for the optimization of trajectory functionals with constraints. IEEE Conference on Decision and Control, 45:864–869, 2006.
- [11] J. Kong, M. Pfeiffer, G. Schildbach, and F. Borrelli. Kinematic and dynamic vehicle models for autonomous driving control design. IEEE Intelligent Vehicles Symposium, 4:1094–1099, 2015.
- [12] D. Limon, I. Alvarado, T. Alamo, and E.F. Camacho. MPC for tracking piecewise constant references for constrained linear systems. Automatica, 44:2382–2387, 2008.
- [13] U. Maeder and M. Morari. Offset-free reference tracking with model predictive control. Automatica, 46:1469–1476, 2010.
- [14] T. Schanz. Relaxed barrier function based model predictive tracking control of a sports car. Master's thesis, Institute for Systems Theory and Automatic Control, 2018. Advisor: F. Pfitz and C. Ebenbauer.
- [15] D. Simon, J. Lofberg, and T. Glad. Reference tracking MPC using dynamic terminal set transformation. IEEE Transactions on Automatic Control, 59:2790–2795, 2014.
- [16] R. Skjetne, T. Fossen, and P. Kokotović. Robust output maneuvering for a class of nonlinear systems. Automatica, 40:373–383, 2004.

# Prediction of Highway Lane Changes Based on Prototype Trajectories

**David Augustin M.Sc., Marius Hofmann B.Sc.,**

Opel Automobile GmbH, Rüsselsheim;

**Prof. Dr.-Ing. Ulrich Konigorski, Technische Universität Darmstadt**

## Abstract

The vision of automated driving is to increase both road safety and efficiency, while offering passengers a convenient travel experience. This requires that autonomous systems correctly estimate the current traffic scene and its likely evolution. In highway scenarios early recognition of cut-in maneuvers is essential for risk-aware maneuver planning. In this paper, a statistical approach is proposed, which advantageously utilizes a set of prototypical lane change trajectories to realize both early maneuver detection and uncertainty-aware trajectory prediction for traffic participants. Generation of prototype trajectories from real traffic data is accomplished by Agglomerative Hierarchical Clustering. During clustering, the alignment of the cluster prototypes to each other is optimized and the cohesion of the resulting prototype is limited when two clusters merge. In the prediction stage, the similarity of observed vehicle motion and typical lane change patterns in the data base is evaluated to construct a set of significant features for maneuver classification via Boosted Decision Trees. The future trajectory is predicted combining typical lane change realizations in a mixture model. B-splines based trajectory adaptations guarantee continuity during transition from actually observed to predicted vehicle states. Quantitative evaluation results demonstrate the proposed concept's improved performance for both maneuver and trajectory prediction compared to a previously implemented reference approach.

**Keywords** maneuver detection, trajectory prediction, motion pattern recognition, highly automated driving, boosted decision trees

## 1. INTRODUCTION

The development of automated driving functions is a central activity of industry and science. Currently, first assistance systems combining both longitudinal and lateral guidance are introduced on the market. In order to autonomously drive in public traffic these systems need to correctly evaluate the current traffic scene and its likely evolution. This includes estimating the driving intentions of traffic participants, detecting maneuvers being performed, and predicting future motion of surrounding traffic. All these tasks are non-deterministic and uncertainties in maneuver and motion estimation need to be considered. In this contribution, highly automated driving (HAD) on highways is addressed with the focus on early lane change maneuver detection and uncertainty-aware trajectory prediction. Before outlining the basic concepts of the proposed approach in Subsection 1.2 an overview of related work in the field of motion prediction is provided.

## 1.1. RELATED WORK

Motion prediction is a research area since decades. The survey articles [2] and [3] provide overviews about a variety of published approaches and fields of application related to road transport. Additionally, both provide suggestions on how motion prediction approaches can be categorized.

Regarding driver intention recognition, a large number of approaches do assess the traffic environment on an abstract level while neglecting the prediction of physical motion which is crucial for criticality assessment and trajectory planning. The opposite concept relying purely on physically-based motion prediction is only valid for a limited time horizon of less than a second [2]. Approaches that realize both motion detection and trajectory prediction can be classified as methods of pattern recognition and methods fusing dynamic motion models with behavior descriptions [4]. Methods of pattern recognition do not only consider the current state of an object but also its history. These states are compared to a database of previously generated motion patterns, each linked to a specific maneuver type. In scenarios like intersections, in which the road topology predefines typical trajectories, the patterns can be directly created from map data [5]. In [6] trajectory prediction for lane changes is realized combining a physical motion model with artificially created motion patterns. At each time step a new set of motion patterns is generated based on the current vehicle state, the road parameters, and the detected maneuver. Another possibility for pattern creation is to analyze real traffic data. The approach [7] utilizes a set of recorded highway lane change trajectories as prototypes in a Bayesian network classifier for maneuver detection. Clustering methods are not applied [8]. Motion prediction for traffic participants is realized using multi-agent simulation. In [9] a cluster-based technique that learns the typical motion patterns using pairwise clustering is designed for a visual pedestrian tracking system placed in an entry hall. For static environments like interior rooms of buildings or intersections it is fairly easy to define regions of start and end points of motion patterns compared to environments with varying topology like highways.

## 1.2. PROPOSED APPROACH

In this contribution we propose an extension to a previously published approach for lane change maneuver detection and uncertainty-aware trajectory prediction in highway scenarios [10]. The approach is centered around the idea that the variety of lane change realizations can be clustered into typical motion patterns which support early maneuver recognition and trajectory prediction. Similar lane change courses are aggregated into groups, each represented by a prototype trajectory. Figure 1 shows a schematic diagram of the proposed approach.

The objectives of learning stage are to produce a set of representative lane change trajectories, which can be utilized to formulate descriptive features for maneuver recognition, and to learn a convenient classification algorithm. Prototype trajectories are generated from recorded highway footage of traffic participants applying Agglomerative Hierarchical Clustering (AHC) in combination with a preprocessing step optimizing the trajectory alignment. Additionally, constraints are introduced to improve cluster cohesion

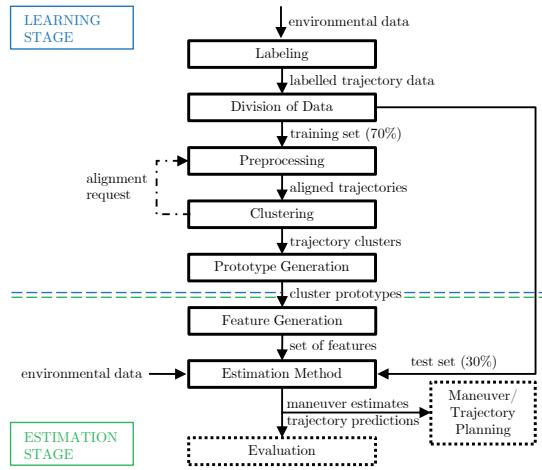


Figure 1: Process diagram of the proposed approach. Maneuver and trajectory estimates can be used as inputs for HAD maneuver and trajectory planning.

and define the end condition for pairwise clustering. To reduce the diversity of lane change embodiments and thus limit the number of required representatives we categorize lane change trajectories solely by their lateral course. This enables maneuvers of different absolute velocity but similar lateral movement to be cumulated in the same cluster. Each lane change cluster is represented by lateral position and velocity prototypes. Details of typical motion pattern extraction from real traffic data are provided in Chapter 3.

In the estimation stage, which is covered in Section 4, we buffer the latest states for each Vehicle Of Interest (VOI). The vehicle state histories are referred to as partially observed trajectories. A distance value is computed for each pair of partial and prototype trajectory under optimal alignment for lateral position and velocity independently. For each lane change type (Lane Change Left (LCL) or Lane Change Right (LCR)) we select the pairs with minimal distances as best matches. The distance values of the best matches for LCL and LCR are utilized to construct features for maneuver detection. Additionally, the lateral offset of a vehicle within its lane and its lateral velocity is applied for maneuver inference. All these features are derived from motion states of each VOI, individually. Vehicle interdependencies or infrastructure information are not taken into account. This limits the possible prediction horizon because potential causes for lane change maneuvers are not considered. Maneuvers can only be detected during execution. On the other hand, approaches with lower abstraction level limit the requirements on environment sensing system (Section 2), i.e. there is no need to detect the vehicle driving in front of a VOI in order to reason about its influence on driving intentions. Due to the choice of features the proposed approach can be categorized as maneuver-based driver intention estimation.

The extensions compared to our previous publication [10] mainly lie in advances of prototype usage for both maneuver detection and maneuver-based trajectory prediction. We train an ensemble of decision trees by adaptive boosting for maneuver classification and discuss its performance in comparison to the generative classifier Gaussian Discriminant Analysis (GDA). The trajectories of the VOIs are predicted according to the estimated maneuvers. In the case of lane changes, the future lateral motion is expressed as a weighted sum of all maneuver-related prototypes forming a Gaussian Mixture Model (GMM). The weight of each prototype correlates with its proximity to the partially observed trajectory. Initial offsets between the actual lateral position of a VOI and the trajectory prediction are compensated by applying a B-spline approximation. Longitudinal motion is covered independently by a (nearly) constant acceleration model. Both classification and motion prediction are evaluated with a test set of recorded highway data. The results are discussed in Section 6.

## 2. ENVIRONMENT SENSING

The test vehicle is equipped with various radars and cameras for all-round object recognition. As we are interested in cut-in maneuver detection, we focus on vehicles located in the front of the test car.

A tracking system produces, for each sensed object, a local estimate of its state vector  $\mathbf{X}^{(\text{target})}$ :

$$\mathbf{X}^{(\text{target})} = [x, y, \theta, v]^T \quad (1)$$

where  $x$  and  $y$  are local Cartesian coordinates,  $\theta$  the relative heading angle, and  $v$  the absolute velocity. The camera system detects lane markings and approximates their course as cubic functions in the local coordinate system:

$$y(x) = c_3x^3 + c_2x^2 + c_1x + c_0 \quad (2)$$

with polynomial coefficients  $c_3$ ,  $c_2$ ,  $c_1$ , and  $c_0$ .

To be independent of the ego motion of the test vehicle, the states of all tracked objects are transformed into the Frenet frame. Centerlines of corresponding driving lanes of each traffic object are utilized as reference curves. Vehicle trajectories  $\gamma_i(t) : [0, T_i] \rightarrow \mathbb{C}$  are expressed in the lane-relative configuration space  $\mathbb{C}$  which is  $[s, \dot{s}, d, \dot{d}]$  with  $s$  being the traveled distance from the start of the maneuver,  $\dot{s}$  the velocity in longitudinal direction, while  $d$  and  $\dot{d}$  being the lateral offset to the lane's centerline and the lateral velocity, respectively. To cut down diversity of maneuver executions, the configuration space  $\mathbb{C}$  is reduced to  $[d, \dot{d}]$  for cluster learning and representation. The lateral offset,  $d$ , can be derived using the minimal distance of the vehicle to its left,  $d_l$ , and right lane markings,  $d_r$ :

$$d = \frac{1}{2}(d_l + d_r) \quad (3)$$

Thereby, the lane width is taken into account inherently. To reduce computational effort for the calculation of  $d_l$  and  $d_r$ , lane marker polynomials are locally linearized. The maximal error of this approximation is below our measurement accuracy. The lateral velocity,  $\dot{d}$ , is derived by applying a low-pass filtered difference quotient. The longitudinal velocity,  $\dot{s}$ , is assumed to be equal to the vehicle's absolute velocity,  $v$ . The traveled distance,  $s$ , between two consecutive measurements is computed applying a constant velocity model [10].

### 3. MOTION PATTERN RECOGNITION

Due to diversity of traffic situations and individual driving styles the courses of lane changes highly vary. Nevertheless, we assume that the variety of lane change realizations can be mapped to a finite number of typical motion patterns. Such a pattern represents a group of similar maneuver executions. As the number of clusters and the course of their representing trajectories are unknown, real highway traffic data is analyzed by a prototype-based clustering technique called Agglomerative Hierarchical Clustering. Each maneuver type is analyzed separately. The structured highway environment limits vehicle maneuvers with respect to their lateral motion to Lane Change Left, Lane Keeping, and Lane Change Right. Each data point in the data set is assigned to one maneuver type via automatic labeling.

#### 3.1. LABELING

Lane changes can easily be detected in a data set by searching for lane marker crossings. A more challenging aspect for reliable automatic labeling is to define start and end time of a maneuver. Before a vehicle passes the centerline of its starting lane we regard the motion as lane centering and assign it to the lane keeping maneuver. Also a possible overshoot on the target lane is treated as lane keeping. Additionally, it was determined that a maneuver bound is reached when the vehicle's absolute lateral velocity exceeds or undercuts a velocity threshold of 0.2 m/s. To improve the lateral velocity estimate, we approximate the vehicle's position course via B-spline curve and calculate lateral velocity,  $\dot{d}$ , via derivation.

#### 3.2. PREPROCESSING AND CLUSTERING

Objectives of traffic-related motion pattern recognition are to automatically assign similar vehicle trajectories to the same cluster and to compute a common representation for each group, which we denote as prototype trajectory. Due to formulation of goals prototype-based clustering methods, like AHC or k-Means, are suitable solution approaches. Both methods were investigated and compared in [10] with AHC performing superior for highway scenarios.

AHC is an algorithm iteratively merging the two closest clusters until only one single cluster exists or a termination condition is fulfilled [11]. Initially, each cluster is formed by a unique trajectory of the training

data set. When two clusters are merged, they are replaced by a common prototype and their similarity to all other cluster representatives must be reevaluated. Cluster representations consist of time-dependent mean,  $\mu(t)$ , and variance,  $\sigma(t)$ , values. The mean of one cluster,  $C_m$ , is calculated from its comprised trajectories by:

$$\mu_m(t) = \frac{1}{N_m} \sum_{i=1}^{N_m} d_i(t) \quad (4)$$

with  $N_m$  denoting the total number of trajectories in the cluster. For prototype generation, AHC is only applied to position trajectories,  $d \in \mathbb{D}$ .  $\mathbb{D}$  denotes the set of position trajectories relative to the centerline of the driving lane. For maneuver classification, it turned out to be beneficial to utilize both position and velocity prototypes, so in this case  $d \in \mathbb{D} \times \mathbb{V}$  with  $\mathbb{V}$  denoting the set of velocity trajectories [10].

The scatter of cluster trajectories around the prototype mean is expressed via the variance

$$\sigma_m^2(t) = \frac{1}{N_m} \sum_{i=1}^{N_m} (d_i(t) - \mu_m(t))^2 \quad (5)$$

In order to express the relation between two trajectories a measure of proximity is required. We chose the average Euclidean distance between the two trajectories  $d_i, d_j \in \mathbb{D}$  as dissimilarity measure:

$$\delta(d_i, d_j) = \left( \frac{1}{T} \int_{t=t_{\min}}^{t_{\max}} (d_i(t) - d_j(t))^2 dt \right)^{1/2} \quad (6)$$

$$t_{\min} = \min(t_{0,i}, t_{0,j})$$

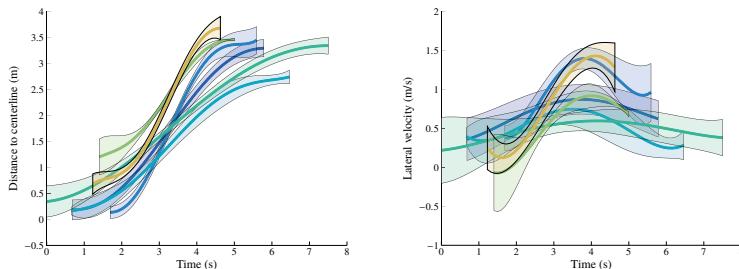
$$t_{\max} = \max(t_{0,i} + T_i, t_{0,j} + T_j)$$

$$T = t_{\max} - t_{\min}$$

where  $t_{0,i}$ ,  $t_{0,j}$ ,  $T_i$ , and  $T_j$  are the starting times and the total maneuver durations of trajectories  $d_i$  and  $d_j$ , respectively. For comparison of trajectories of unequal length, the shorter ones are extended by keeping their initial and/or final value. The factor  $\frac{1}{T}$  averages the Euclidean distance to negate the influence of duration of the two trajectories being compared on their dissimilarity value.

A major influence factor on the dissimilarity between two lane change trajectories is their mutual alignment [10], which in the case of highway trajectories is mainly determined by the applied labeling approach. In order to handle possible labeling inconsistencies we studied different approaches for active alignment of trajectories. Best results were achieved by an adjustment strategy minimizing the dissimilarity of each pair of trajectories by computing an individual optimal configuration [10]. In AHC the alignment of cluster representatives needs to be updated after each clustering iteration.

Figure 2 shows prototypical lane change motion patterns created using the presented AHC approach.



(a) Position prototypes for changes to the left lane. (b) Velocity prototypes for changes to the left lane.

Figure 2: Prototypical lane change trajectories created by Agglomerative Hierarchical Clustering. For each lane change type six clusters are created from real traffic data.

#### 4. MANEUVER CLASSIFICATION

Motion prediction for traffic participants can be split into two consecutive tasks. In the first step, the performed maneuvers need to be detected. Subsequently, the most probable future trajectories according to the maneuver estimate can be calculated. Maneuver detection is a typical classification problem. The highway topology limits the set of possible lateral maneuvers to  $C = \{\text{LCL, LK, LCR}\}$ . We implemented maneuver inference based on a set of features which can be derived from the observed motion of individual vehicles. Vehicle interaction is not taken into account. This approach reduces computational and sensory requirements. Additionally, not relying on strong assumptions about vehicle interdependencies increases robustness. On the other hand, maneuvers can only be recognized during their execution, thus limiting the possible prediction horizon. The applied features for maneuver detection of a VOI are lateral offset within its lane, lateral velocity and proximity of its motion path to prototype lane change trajectories in the database. The proximity of a partially observed trajectory,  $d_p$ , and a cluster prototype,  $c_m$ , can be calculated via average Mahalanobis  $L_1$  distance:

$$\Delta(d_p, c_m, \tau_m) = \frac{1}{T_m} \int_{-T_m}^0 \left( \frac{(d_p(t) - \mu_m(t + \tau_m))^2}{\sigma_m^2(t + \tau_m)} \right)^{1/2} dt \quad (7)$$

$$T_m = \min(T_{\text{buffer}}, \tau_m)$$

The evaluation period,  $T_m$ , is the minimum of buffered partial trajectory and prototype trajectory length. The cluster prototype is shifted by  $\tau_m$  optimizing the trajectories' adjustment by minimizing their dissimilarity within the recent 0.5 s [10]. Compared to the Euclidean distance, utilized during clustering, the Mahalanobis distance measure takes the non-uniform uncertainty of the prototype course into account. Dissimilarities in regions of low variance have increased weight due to the term  $\frac{1}{\sigma_m^2}$ . Mahalanobis distance of position trajectories is denoted as  $\Delta_p$ . The notation in case of velocity trajectories is  $\Delta_v$ . During feature generation a vehicle's partial trajectory is matched individually to all prototype trajec-

ries in the database. For each pair  $\{d_p, c_m\}$  the optimal shifting coefficient,  $\tau_m$ , is calculated minimizing  $\Delta_{p,[-0.5,0]}(d_p, c_m)$ . The velocity-dependent distance  $\Delta_v(d_p, c_m)$  related to the same cluster is calculated for an equal value of  $\tau_m$ . As the best matching prototypes for LCL and LCR we select those minimizing the dissimilarity  $\Delta_p$  for the whole evaluation period. Their dissimilarity values are denoted  $\Delta_{p,LCL}$ ,  $\Delta_{v,LCL}$ ,  $\Delta_{p,LCR}$  and  $\Delta_{v,LCR}$ .

In [10] a Quadratic Gaussian Discriminant Analysis (GDA) classifier is applied for maneuver inference. In this contribution its performance is compared to Boosted Decision Trees (BDT), an ensemble of shallow decision trees sequentially trained by a boosting method, described in Section 4.1.

#### 4.1. BOOSTING

Boosting is a sequential method for consecutively fitting a set of basic learners to variations of the training data. After each iteration, the whole training set is evaluated [15]. Misclassified data points are given greater weights when used to train the next classifier. Basic learners, also referred to as "weak learners" [13], typically have low classification performance when applied individually. In an ensemble of  $N$  basic learners, each unit provides a class vote dependent on observed features. Those votes are weighted by  $\alpha_n$  and combined like:

$$y(f) = \sum_{n=1}^N \alpha_n h_n(f) \quad (8)$$

with  $h_n$  denoting the hypothesis of the  $n$ -th basic learner. We apply the AdaBoost.M2 algorithm which is applicable in classification problems with multiple class instances [16]. In AdaBoost.M2 weighting coefficients  $\alpha_n$  are derived from weighted pseudo-loss functions, providing more accurate basic classifiers with a greater weight.

As basic classifiers we use shallow decision trees limiting the maximum number of branch nodes to 15. The ensemble classifier comprises 90 basic decision trees. Treated individually, decisions are easily interpretable. They are not limited to a specific type of data. The flexibility of decision trees is extended by enlargement to ensemble methods at the expense of easy interpretability. AdaBoost application does not require hyperparameter training and showed best performance in an extensive empirical comparison [17].

#### 5. MANEUVER-BASED TRAJECTORY PREDICTION

After successful driver intention recognition, the future trajectory of a vehicle is predicted according to the estimated maneuver. In [10] the potential of prototype trajectories for both longitudinal and lateral motion prediction was demonstrated. In case of detected lane changes, the best matching prototype of the respective maneuver type, LCL or LCR, was selected as an estimate for future lateral motion. Here,

we extend this idea by formulating a Gaussian mixture model combining and weighting the predictions of all prototype trajectories of the estimated maneuver type. The predicted lateral course can be calculated as a weighted sum of the prototype means:

$$\mu(t) = \sum_m w_m \hat{\mu}_m(t) \quad (9)$$

and the combined variance can be computed by:

$$\sigma^2(t) = \sum_m w_m (\hat{\sigma}_m^2(t) + \hat{\mu}_m^2(t)) - \mu^2(t) \quad (10)$$

The final values of mean and variance are hold when individual prototypes are evaluated outside their definition range.

$$\hat{\mu}_m(t) = \begin{cases} \mu_m(\tau_m + t), & \tau_m + t < T_m \\ \mu_m(T_m), & \text{otherwise} \end{cases} \quad (11)$$

$$\hat{\sigma}_m^2(t) = \begin{cases} \sigma_m^2(\tau_m + t), & \tau_m + t < T_m \\ \sigma_m^2(T_m), & \text{otherwise} \end{cases} \quad (12)$$

The weighting factors,  $w_m$ , are derived from the ratio of inversed Mahalanobis distance of each prototype representing a motion pattern of the detected maneuver to the partial trajectory:

$$w_m = \frac{\frac{1}{\Delta(d_p, \mu_m)}}{\sum_m \frac{1}{\Delta(d_p, \mu_m)}}. \quad (13)$$

Figure 3 depicts the mean and variance values of the prototype ensemble for different prediction horizons. The longitudinal motion during a lane change maneuver can be described by a (nearly) constant acceleration model [10], also referred to as discrete Wiener process acceleration model [18]. It is given by:

$$\begin{bmatrix} s_{k+1} \\ v_{s_{k+1}} \\ a_{s_{k+1}} \end{bmatrix} = \begin{bmatrix} 1 & T & \frac{1}{2}T^2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} s_k \\ v_{s_k} \\ \bar{a} \end{bmatrix} + \begin{bmatrix} \frac{1}{2}T^2 \\ T \\ 1 \end{bmatrix} \omega_a \quad (14)$$

with

$$\omega_a = \mathcal{N}(0, \sigma_a^2) \quad (15)$$

In [10] the constant acceleration value is calculated averaging the longitudinal accelerations of all trajectories comprised in the cluster, which is the best fit to the vehicles' partial trajectory.  $\sigma_a^2$  is the related variance. Using the Gaussian mixture model, the new values of  $\bar{a}$  and  $\sigma_a^2$  can be computed via Equations 9 and 10, respectively.

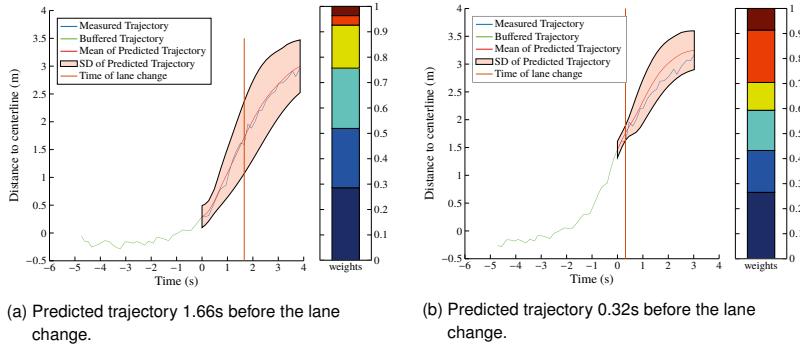


Figure 3: Predicted trajectories (colored red) at two different time points before a lane change left. The vehicle's true motion is plotted in green for past states and in blue for future observations. The lane change event is indicated by a vertical red line. Bar plots depict the individual weights of each prototype in the ensemble model.

## 5.1. SMOOTH TRANSITION TO PROTOTYPE-BASED TRAJECTORY PREDICTIONS

The future lateral motion course, predicted based on the previously proposed model of mixed cluster representatives, does not necessarily pass through the currently observed state of the vehicle. Therefore, the transition from current lateral offset to future values is generally discontinuous. To solve this problem, we adapt all cluster prototypes that contribute to the predicted trajectory within the interval  $[\tau_m, \tau_m + 1 \text{ s}]$ . This ensures continuity in lateral position, velocity, and acceleration also in the near future. The adaptations are based on transformation of the lateral position course into B-splines. B-splines and their basis functions have favorable characteristics allowing adaptations in limited scope (local support characteristic) and guaranteeing continuity of a function and their derivatives of certain degree (continuity characteristic) [19]. B-splines are piecewise polynomial curves of degree  $d$  defined on an interval  $[a, b]$ . They are represented by a knot vector  $\mathbf{t} = [t_0, t_1, \dots, t_m]$  with  $m + 1$  elements and a set of  $n + 1$  control points  $\mathbf{P} = \{P_0, \dots, P_n\}$ . The relation  $n + 1 = m + d$  is always valid.

B-Spline curves are represented by

$$\mathbf{C}(t) = \sum_{i=0}^n \mathbf{P}_i N_{i,d}(t) \quad (16)$$

where the basis functions  $N_{i,d}(t)$  are recursively defined as

$$N_{i,0}(t) = \begin{cases} 1, & t \in [t_i, t_{i+1}) \\ 0, & \text{otherwise} \end{cases} \quad (17)$$

$$N_{i,d}(t) = \frac{t - t_i}{t_{i+d} - t_i} N_{i,d-1}(t) + \frac{t_{i+d+1} - t}{t_{i+d+1} - t_{i+1}} N_{i+1,d-1}(t). \quad (18)$$

Initially, a cluster's polynomial representation  $f(t) = \mathbf{a}_0 + \mathbf{a}_1 t + \dots + \mathbf{a}_n t^n$  is converted into a B-spline curve by scaling the polynomial to the interval  $[0,1]$  and calculating the control points [20] by

$$\mathbf{P}_i = \sum_{j=0}^i \frac{\binom{i}{j}}{\binom{d}{j}} \mathbf{a}_j. \quad (19)$$

Due to the local support characteristic, the control point  $\mathbf{P}_i$  only affects the interval  $[t_i, t_{i+p+1})$ . We use this property to modify the trajectory within the first second of prediction by adding three knots at the interval boundaries, respectively.  $C(t)$  is  $d - k = 2$  times continuously differentiable at these breakpoints, with multiplicity  $k = 3$  corresponding to the number of identical knots in the knot vector. The insertion of a new knot  $\hat{t} \in [t_s, t_{s+1})$  causes a new control point. As stated in [20], the elements of the control point set are updated by

$$\hat{\mathbf{P}}_i = \begin{cases} \mathbf{P}_i, & 0 \leq i \leq s-d \\ (1 - \alpha_i) \mathbf{P}_{i-1} + \alpha_i \mathbf{P}_i, & s-d+1 \leq i \leq s \\ \mathbf{P}_{i-1}, & s+1 \leq i \leq n+1 \end{cases} \quad (20)$$

$$\alpha_i = \frac{\hat{t} - t_i}{t_{i+d} - t_i}. \quad (21)$$

Within the first prediction second only a limited number of basis functions are unequal to zero. Due to knot insertion the non-zero basis functions are  $N_{4,5}$ ,  $N_{5,5}$  and  $N_{6,5}$ . The control points of these basis functions need to be adjusted such that the B-spline meets the currently observed vehicle states which are position, velocity and acceleration. According to [20], the  $r$ -th derivative of a B-spline is defined as

$$\mathbf{C}^{(r)}(t) = \sum_{i=0}^{n-r} \mathbf{P}_i^{(r)} N_{i,d-r}^{(r)}(t) \quad (22)$$

where

$$\mathbf{P}_i^{(r)} = (d-r+1) \frac{\mathbf{P}_{i+1}^{(r-1)} - \mathbf{P}_i^{(r-1)}}{t_{i+d+1} - t_{i+r}} \quad (23)$$

with  $\mathbf{P}_i^0 = \mathbf{P}_i$ . The knot vector is reduced to  $t_r, \dots, t_{m-r}$ . This yields the following equation system with three undefined variables  $\mathbf{P}_4$ ,  $\mathbf{P}_5$ , and  $\mathbf{P}_6$ :

$$x = \mathbf{P}_4 N_{4,5}(\tau_m) + \mathbf{P}_5 N_{5,5}(\tau_m) + \mathbf{P}_6 N_{6,5}(\tau_m) \quad (24)$$

$$x' = \mathbf{P}_4^{(1)} N_{4,4}^{(1)}(\tau_m) + \mathbf{P}_5^{(1)} N_{5,4}^{(1)}(\tau_m) \quad (25)$$

$$x'' = \mathbf{P}_4^{(2)} N_{4,3}^{(2)}(\tau_m). \quad (26)$$

The derivatives can be calculated via Equation 23. The vehicle's lateral velocity and acceleration are estimated via derivation of a third-order polynomial approximation of the partial trajectory and inserted into Equations 24, 25, and 26 to solve for the values of the required control points.

## 6. RESULTS

For evaluation and comparison of proposed approaches for maneuver estimation and subsequent trajectory prediction we use the data set proposed in [10]. Aggregating hours of real highway footage, the whole data set comprises a total number of 434 lane change maneuvers of traffic participants of which 156 are lane changes to the left and 278 to the right neighbor lane, respectively. Data is divided with a ratio of 70/30 into training and test set. During data division it is specially requested that ratio of maneuver types is equal in both fractions of the data set. In terms of maneuver classification we compute performance measures juxtaposing GDA and boosting decision trees. As the distribution of classes is highly unequal, with lane keeping clearly outnumbering lane change maneuvers, balanced versions of performance measures are applied. The advances in trajectory prediction, namely combining prototype trajectories in a Gaussian mixture model and B-spline based trajectory smoothing, are compared to the previously implemented approach [10], which utilized solely the best matching cluster representative for future motion prediction.

### 6.1. EVALUATION OF MANEUVER DETECTION

Due to the highly unequal class incidences, balanced measures [7] must be applied for classification performance evaluation, whenever a quality criterion combines actual positive and actual negative portions of the regarded class (e.g. precision):

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} = 1 - \text{FNR} \quad (27)$$

$$\text{PRC} = \frac{\text{TPR}}{\text{TPR} + \text{FPR}} \quad (28)$$

$$F_1 = \frac{2 \cdot \text{PRC} \cdot \text{TPR}}{\text{PRC} + \text{TPR}} \quad (29)$$

The True Positive Rate TPR, also denoted recall, states how likely a maneuver will be predicted by the respective approach. The precision PRC indicates how likely a predicted lane change will actually happen. The  $F_1$  score is the harmonic mean of both precision and recall. Those values are computed on the whole test data set. Table 1 shows the classification performance for the proposed methods, Quadratic Gaussian Discriminant Analysis and Boosted Decision Trees, using two different sets of features, respectively. As a reference, to investigate the influence of features constructed from cluster prototypes, both methods are evaluated utilizing a two-dimensional feature vector  $f = [d, \dot{d}]^T$  comprising lateral offset,  $d$ , and lateral velocity,  $\dot{d}$ , of a vehicle in Frenet coordinates. In case of GDA we constructed two features utilizing distance values to the best matching prototypes by:

$$f_3 = \Delta_{p,\text{LCR}} - \Delta_{p,\text{LCL}} \quad (30)$$

$$f_4 = \Delta_{v,\text{LCR}} - \Delta_{v,\text{LCL}} \quad (31)$$

Thereby, the dimension of the feature vector can be kept low while achieving good prediction results. For BDT classifier we expand the feature vector to six dimensions  $f = [d, \dot{d}, \Delta_{p,LCR}, \Delta_{p,LCL}, \Delta_{v,LCR}, \Delta_{v,LCL}]^T$ , allowing the ensemble model to learn mutual dependencies of features. Application of this feature vector for GDA worsens prediction quality, most likely because model assumptions are violated. For the sake of comparison all classifiers were trained allowing a miss rate for the lane keeping maneuver of  $MCR_{LK} = 0.11$ . This is realized via adaptation of prior probabilities for GDA and initial weights of the data points for BDT.

Table 1: Maneuver classification performance of Quadratic Gaussian Discriminant Analysis (GDA) and Boosted Decision Trees (BDT) for different sets of features.

Approach	Features	Maneuver	Miss Rate	Recall	Precision	$F_1$ -Score	Avg. Prediction Time
GDA	$d, \dot{d}$	LCL	0.18	0.82	0.95	0.880	1.54
		LK	0.11	0.89	0.81	0.849	
		LCR	0.23	0.77	0.94	0.845	
GDA	$d, \dot{d}, \Delta_{p,LCR} - \Delta_{p,LCL}, \Delta_{v,LCR} - \Delta_{v,LCL}$	LCL	0.16	0.84	0.96	0.894	1.68
		LK	0.11	0.89	0.82	0.855	
		LCR	0.22	0.78	0.93	0.851	
BDT	$d, \dot{d}$	LCL	0.13	0.87	0.96	0.915	1.61
		LK	0.11	0.89	0.85	0.870	
		LCR	0.18	0.82	0.94	0.872	
BDT	$d, \dot{d}, \Delta_{p,LCR}, \Delta_{p,LCL}, \Delta_{v,LCR}, \Delta_{v,LCL}$	LCL	0.11	0.89	0.96	0.921	1.67
		LK	0.11	0.89	0.85	0.874	
		LCR	0.18	0.82	0.94	0.877	

## 6.2. DISCUSSION OF MANEUVER DETECTION PERFORMANCE

First, the influence of features constructed from cluster prototypes on the classification performance is investigated for both learning methods. GDA strongly benefits from additional information provided by prototype trajectories. The average prediction time can be increased by 0.14s to a total of 1.67s. The performance measures show improvements, as well. The increase in average prediction time of 0.06s for the BDT method by adding prototype-derived features is comparatively small, but again, the prediction quality measures denote performance improvements.

For the two-dimensional feature vector  $f = [d, \dot{d}]^T$  BDT performs significantly better reaching an improved prediction time and higher  $F_1$ -scores. Whereas the precision values are on equal level, the major improvements are reported by increased recall values for lane change maneuvers, which means that actual lane

changes are more likely to be detected. Incorporating information provided by motion pattern recognition, both GDA and BDT achieve equal average prediction horizons of roughly 1.7 s, while, again, BDT method shows better values for performance measures. The optimal average prediction horizon according to the automatically labeled data can be calculated to 2 s.

### 6.3. EVALUATION OF MOTION PREDICTION

An advantage of prototype-based maneuver detection lies in the usability of cluster prototypes for the future motion prediction of traffic participants. Here, the extended approach for trajectory prediction, as described in Section 5, is evaluated and compared to the original version presented in [10].

Figure 4 shows the mean absolute lateral and longitudinal errors between traffic participants' predicted and actual positions for different prediction horizons. The evaluation results for the reference approach is illustrated on left, while the new motion prediction results are depicted on the right side of the figure. The prediction horizon [0 s, 4 s], which is plotted on the horizontal axis, is subdivided into intervals of  $\Delta t = 0.5$  s. For the  $n$ -th prediction interval, the mean absolute position error is calculated by

$$\varepsilon_n = \frac{1}{N_n} \cdot \sum_{\tau \in [n\Delta T, (n+1)\Delta T]} |\mathbf{x}_t - \hat{\mathbf{x}}_{(t|\tau)}| \quad (32)$$

where  $N_n$  is the total number of summands,  $\mathbf{x}_t = [s_t, d_t]$  denotes the actual observation at time  $t$  and  $\hat{\mathbf{x}}_{(t|\tau)}$  is the prediction of vehicle state at time  $t$  calculated at time  $t - \tau$ . The maximum evaluation time is limited by the length of the prototype ensemble used for motion prediction and capped to a value of 4 s. The evaluation starts when the correct lane change maneuver is detected continuously and ends at the point in time when the vehicle crosses the lane marking.

### 6.4. DISCUSSION OF MOTION PREDICTION PERFORMANCE

For longitudinal trajectory prediction during lane change maneuvers both approaches perform equally well. Comparing both lane change types, the errors are generally larger in case of LCL maneuvers. The reason for this lies in the larger diversity of longitudinal accelerations during lane changes to the left.

The performance in lateral motion prediction is significantly improved by the extensions presented in Section 5. For small prediction horizons, the absolute position errors correspond approximately to the measurement accuracy. For a prediction of horizon of 2 – 4 s, the absolute lateral error is steady with an approximate value of 0.3 m. In case of the reference approach, error peaks for medium prediction horizons can be observed. These peaks result from incorrect selections of prototype trajectories in an early stage of the detected maneuver. At the beginning many cluster prototypes are similar so that wrong prototype selection is quite likely. The combination of prototypes in a Gaussian mixture model can compensate this issue.

Figure 5 plots the average Mahalanobis distance between traffic participants' predicted and actual lateral

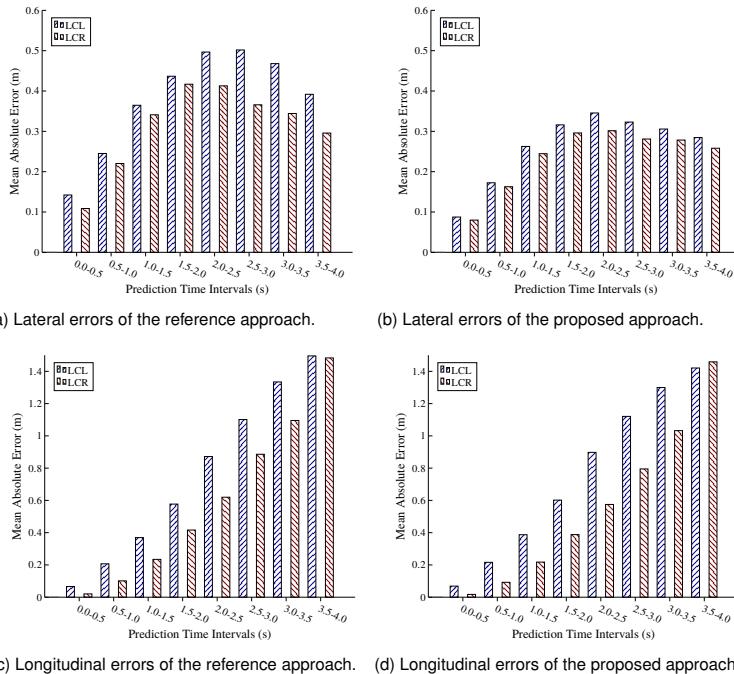


Figure 4: Mean absolute errors between the traffic participants' predicted and actual positions for various prediction horizons.

offsets. The upper bound for all considered prediction horizons is  $0.7\sigma$ , which indicates that the variance of the prototype ensemble, which is calculated utilizing Equation 10, is a good estimate of prediction uncertainty.

## 7. CONCLUSION AND OUTLOOK

In this paper, a statistical approach is proposed, which successfully utilizes a set of prototypical lane change trajectories to realize both early maneuver detection and uncertainty-aware trajectory prediction for traffic participants. Generation of prototype trajectories from real traffic data is accomplished by Agglomerative Hierarchical Clustering, optimizing mutual cluster configurations and constraining cohesion during the clustering process [10]. The main contributions of this paper exist in targeted adaptations of prediction methods to improve utilization of motion patterns and thus enhancing prediction results. For maneuver recognition, we implemented Boosted Decision Trees classification increasing the detection rate of lane change maneuvers compared to previously applied Gaussian Discriminant Analysis. The future trajectory is predicted according to typical realizations of the estimated maneuver. We introduced

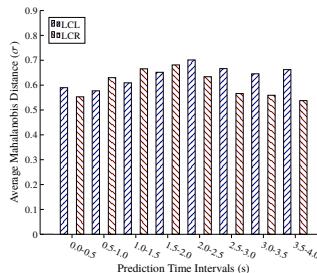


Figure 5: Mean lateral Mahalanobis distance between the traffic participants' predicted and actual positions for various prediction horizons.

a mixture model of cluster prototypes and demonstrated increased accuracy for lateral motion prediction. Additionally, a B-splines based adaptation technique is described guaranteeing continuity during transition from actually observed to predicted vehicle states. In future work, the prediction framework is extended by taking interaction between traffic participants into account to further increase the prediction horizon and lower misclassification rates.

## REFERENCES

- [1] SAE International. Automated driving: levels of driving automation are defined in new sae international standard j3016. 2014.
- [2] Stéphanie Lefèvre, Dizan Vasquez, and Christian Laugier. A survey on motion prediction and risk assessment for intelligent vehicles. *Robomech Journal*, 1(1):1, 2014.
- [3] Martin Liebner and Felix Klanner. Fahrerabsichtserkennung und Risikobewertung. In Hermann Wimmer, Stephan Hakuli, Felix Lotz, and Christina Singer, editors, *Handbuch Fahrerassistenzsysteme*, pages 701–719. Springer Fachmedien Wiesbaden, Wiesbaden, 2015.
- [4] Matthias Schreier, Volker Willert, and Jürgen Adamy. An integrated approach to maneuver-based trajectory prediction and criticality assessment in arbitrary road environments. *IEEE Transactions on Intelligent Transportation Systems*, 17(10):2751–2766, 2016.
- [5] Thierry Wyder, Georg Schildbach, Stéphanie Lefevre, and Francesco Borrelli. A bayesian filter for modeling traffic at stop intersections. In *Intelligent Vehicles Symposium (IV), 2015 IEEE*, pages 1252–1257. IEEE, 2015.
- [6] Adam Houenou, Philippe Bonnifait, Véronique Cherfaoui, and Wen Yao. Vehicle trajectory prediction based on motion model and maneuver recognition. In *Intelligent Robots and Systems (IROS), 2013 IEEE/RSJ International Conference on*, pages 4363–4369. IEEE, 2013.

- [7] Mohammad Bahram, Constantin Hubmann, Andreas Lawitzky, Michael Aeberhard, and Dirk Wollherr. A combined model-and learning-based framework for interaction-aware maneuver prediction. *IEEE Transactions on Intelligent Transportation Systems*, 17(6):1538–1550, 2016.
- [8] Mohammad Bahram. *Interactive Maneuver Prediction and Planning for Highly Automated Driving Functions*. Dissertation, Technische Universität München, München, 2017.
- [9] Dizan Vasquez and Thierry Fraichard. Motion prediction for moving objects: a statistical approach. In *Robotics and Automation, 2004. Proceedings. ICRA'04. 2004 IEEE International Conference on*, volume 4, pages 3931–3936. IEEE, 2004.
- [10] David Augustin, Marius Hofmann, and Ulrich Konigorski. Motion pattern recognition for maneuver detection and trajectory prediction on highways. In *International Conference on Vehicular Electronics and Safety (ICVES), 2018 IEEE*. IEEE, 2018.
- [11] Pang-Ning Tan, Michael Steinbach, and Vipin Kumar. *Introduction to data mining*. Pearson, 2005.
- [12] Mia Hubert and Katrien Van Driesssen. Fast and robust discriminant analysis. *Computational Statistics & Data Analysis*, 45(2):301–320, 2004.
- [13] Kevin P. Murphy. *Machine learning: A probabilistic perspective*. Adaptive computation and machine learning. 2012.
- [14] Sabine Verboven and Mia Hubert. Matlab library libra. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(4):509–515, 2010.
- [15] Christopher M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag, Berlin, Heidelberg, 2006.
- [16] Yoav Freund and Robert E Schapire. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1):119–139, 1997.
- [17] Rich Caruana and Alexandru Niculescu-Mizil. An empirical comparison of supervised learning algorithms. In *Proceedings of the 23rd international conference on Machine learning*, pages 161–168. ACM, 2006.
- [18] Yaakov Bar-Shalom, X Rong Li, and Thiagalingam Kirubarajan. *Estimation with applications to tracking and navigation: theory algorithms and software*. John Wiley & Sons, 2004.
- [19] Les Piegl and Wayne Tiller. *The NURBS book*. Springer Science & Business Media, 2012.
- [20] Duncan Marsh. *Applied geometry for computer graphics and CAD*. Springer Science & Business Media, 2006.



# Bewegungssteuerung für ein Robo-Taxi mit Symmetrie in Antrieb und Lenkung

Dr.-Ing. Thomas Raste, Peter Lauer, Continental, Frankfurt am Main

## Zusammenfassung

Continental entwickelt auf der Entwicklungsplattform CUbE (Continental Urban mobility Experience) Lösungen für fahrerlos fahrende Fahrzeuge im städtischen Raum. Robo-Taxis als Teil der modernen Mobilität helfen Staus, Unfälle, Luftverschmutzung und Parkplatznot in Städten zu reduzieren. Der CUbE besitzt einen elektrischen Antrieb und eine elektrische Lenkung an beiden Achsen und stellt damit ein regelungstechnisch überaktuiertes System dar. Die Bewegungssteuerung nutzt den redundanten Satz an Aktoren, in dem sie die Reglerausgangsgrößen optimal auf die verfügbaren Aktoren verteilt. Damit werden Fahrmanöver möglich, die mit einer herkömmlichen Einachs-Lenkung nicht möglich sind, wie z.B. Spurwechsel oder Parkmanöver ohne Gierbewegung.

## Abstract

Based on the development platform CUbE (Continental Urban mobility Experience), Continental is developing solutions for driverless vehicles in urban areas. Robo-Taxis as part of modern mobility helps to reduce traffic jams, accidents, air pollution and parking shortages in cities. The CUbE has an electric drive and electric steering on both axles, making it an over-actuated system. The motion controller uses the redundant set of actuators to optimally distribute the controller output variables among the available actuators. This makes driving maneuvers possible that are not possible with conventional single-axle steering, such as lane changes or parking without yaw movement.

## 1 Robo-Taxis als Teil einer nahtlosen Mobilität

Laut einer Studie des Beratungsunternehmens Roland Berger [11] wird bis zum Jahr 2030 etwa ein Viertel der Transportleistung auf fahrerlose Fahrzeuge entfallen. Der CUbE ist eine Basis, um Systeme und Komponenten von Continental auf die Erfordernisse eines solchen Fahrzeugs zu adaptieren, entwickeln und in verschiedensten Use-Cases zu testen, s. Fig. 1. Das Unternehmen geht davon aus, dass solche Robo-Taxis in Zukunft als Ergänzung des öffentlichen Nahverkehrs eine entscheidende Rolle spielen werden, [8]. Die vollautomatisierten Fahrzeuge schaffen die Möglichkeit, mit öffentlichen Verkehrsmitteln von Tür zu Tür zu

reisen. Als Basis für das Fahrzeug nutzt Continental das Chassis des von dem französischen Unternehmen Easymile vertriebenen Modells EZ10. Der 2014 auf den Markt eingeführte, knapp 4 m lange, 2 m breite und 2,75 m hohe EZ10 fasst bis zu 12 Personen, wiegt bis zu 2750 kg und kann bis zu 40 km/h fahren. Das Shuttle wurde mit einer Vielzahl an Produkten des Continental-Konzerns und eines seiner Joint Ventures erweitert – unter anderem Sensoren, Steuergeräte, Software-Algorithmen, Reifen, Oberflächenmaterialien sowie ein redundantes Brems-, Antriebs- und Lenksystem.



Fig. 1: Fahrerlose Robo-Taxis im zukünftigen urbanen Umfeld

## 2 Bewegungssteuerung mit Symmetrie in Antrieb und Lenkung

Robo-Taxis müssen als fahrerlose autonom fahrende Fahrzeuge im Dauerbetrieb besondere Anforderungen hinsichtlich Sicherheit, Verfügbarkeit und Fehlertoleranz erfüllen. Aus diesem Grund ist die Bewegungssteuerung mehrkanalig und alle Aktoren redundant ausgelegt, s. Fig. 2.

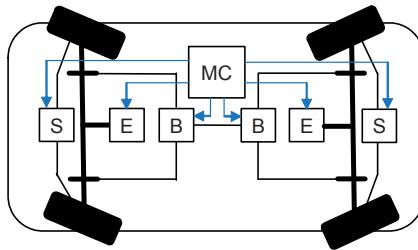


Fig. 2: Die Bewegungssteuerung (Motion Control, MC) wirkt auf die redundanten Aktoren Lenkung (Steering, S), Antrieb (Electric Motor, E) und Reibungsbremse (Brake, B)

Die Ansteuerung der Aktoren gelingt vorteilhaft durch Aufteilen des Regelungssystems in mehrere kaskadierte Ebenen mit eindeutig definierten Schnittstellen untereinander. Die horizontale Bewegung des Fahrzeugs wird festgelegt durch die aktuell anliegenden Radlenkwinkel und Radmomente, die die horizontalen Reifenkräfte bestimmen. Das Grundprinzip der Bewegungssteuerung ist die Betrachtung der umgekehrten Wirkrichtung: Ausgehend von einer gewünschten kinematischen Bewegung werden die zugehörigen dynamischen Kräfte und daraus die entsprechenden Radmomente und Radlenkwinkel als Stellgrößen bestimmt.

Fig. 3 zeigt die Struktur der Regelung mit den funktionalen Komponenten.

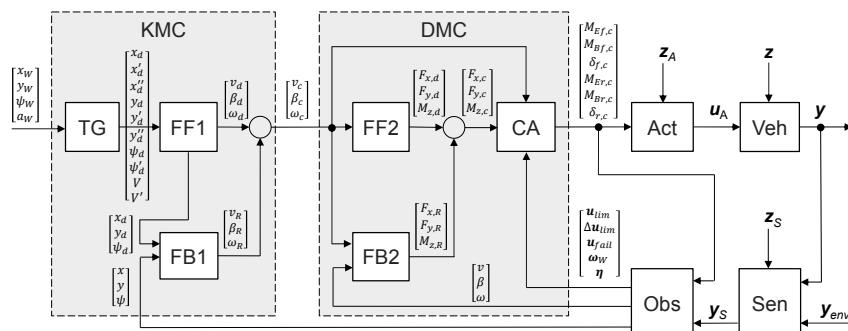


Fig. 3: Kaskadierte kinematische (KMC) und dynamische (DMC) Bewegungssteuerung mit Trajektoriengenerator (TG), Vorsteueranteilen (FF1/2), Regleranteilen (FB1/2), Stellgrößenverteilung (CA) und Beobachtern (Obs) sowie Regelstrecke mit Fahrzeug (Veh), Sensoren (Sen) einschließlich Umfeldmessungen  $y_{env}$  und Aktoren (Act). Die Komponenten der Regelstrecke können von externen Störgrößen  $z_S$ ,  $z_A$  bzw.  $z$  beeinträchtigt werden.

### 3 Auslegung der Bewegungssteuerung

Die Auslegung der Bewegungssteuerung geschieht anhand des Einspurmodells aus Fig. 4 mit den kinematischen Bewegungsgrößen Position  $x$  und  $y$  sowie Gierwinkel  $\psi$ . Die dynamischen Bewegungsgrößen sind die Fahrzeuggeschwindigkeit  $v$ , der Schwimmwinkel  $\beta$  und die Gierrate  $\omega$ . Die Stellgrößen Lenkwinkel  $\delta$  sowie Momente von E-Motor und Reibungsbremse erzeugen die Radkräfte  $F_S$ ,  $F_E$  und  $F_B$  jeweils an den Vorder- und Hinterrädern (Index  $f$  bzw.  $r$ ). Die Radkräfte verursachen die Längs- und Querkräfte  $F_x$  bzw.  $F_y$  angezeigt im Fahrzeugkoordinaten-system. Zusätzlich dargestellt sind die Geschwindigkeiten an den Rädern und im Schwerpunkt sowie die Schräglauwinkel  $\alpha$ .

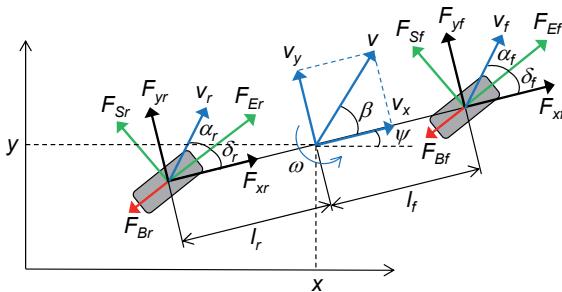


Fig. 4: Einspurmodell zur Auslegung der Bewegungssteuerung

Anzumerken ist, dass das Einspurmodell nach Fig. 4 im Folgenden auch für die Simulation der Regelstrecke zur Validierung der Bewegungssteuerung eingesetzt wird. Hierbei werden nichtlineare Reifenkraftmodelle und Schlupfmodelle, die auch für Stillstand geeignet sind [6], verwendet.

#### 3.1 Trajektoriengenerierung für die kinematische Bewegungssteuerung

Die Eingangsgrößen für die Trajektoriengenerierung kommen aus der Bewegungsplanung und sind Stützstellen für die Positionen  $x_w$  und  $y_w$  sowie Gierwinkel  $\psi_w$  jeweils in äquidistanten Abständen. Zusätzlich wird ein gewünschtes Beschleunigungsprofil  $a_w$  aus der vorgelagerten Planung übertragen. Es wird davon ausgegangen, dass alle Größen für eine gewisse Vorausschaulänge  $N$  zur Verfügung stehen. Mit dem konstanten Weginkrement  $\Delta s$  können die Geschwindigkeit und die Zeit rekursiv an den Stützstellen berechnet werden als

$$V(s_i) = \sqrt{(V(s_{i-1}))^2 + 2a_w(s_i)\Delta s} \quad (1)$$

$$t_i = t_{i-1} + \frac{2\sqrt{(x_w(s_i) - x_w(s_{i-1}))^2 + (y_w(s_i) - y_w(s_{i-1}))^2}}{V(s_i) + V(s_{i-1})} \quad (2)$$

Zusätzlich wird die Ableitung nach dem Weg benötigt, die sich ergibt aus

$$V'(s_i) = \frac{a_W(s_i)}{V(s_i)}, \quad \text{für } V(s_i) \neq 0 \quad (3)$$

Die Trajektoriengenerierung berechnet die Sollgrößen an beliebigen Bahnpunkten  $s$  durch Interpolation zwischen den Stützstellen. Mit der Interpolationsfunktion  $f_{int}$  erhält man z.B. für den Sollwert

$$x_d(s) = f_{int}(x_W(s_1), x_W(s_2), \dots, x_W(s_N)) \quad (4)$$

Splinefunktionen eignen sich besonders als Interpolationsfunktionen, da sie auch die Ableitungen ohne großen Aufwand zur Verfügung stellen. Zur Bestimmung der Tangentialbeschleunigung auf der Sollbahnkurve werden Ableitungen bis zur zweiten Ordnung benötigt, d.h.

$$a_d(t) = \frac{V(s)}{\sqrt{x_d'^2 + y_d'^2}} (x_d'(x_d''V(s) + x_d'V'(s)) + y_d'(y_d''V(s) + y_d'V'(s))) \quad (5)$$

Fig. 5 zeigt einen Beispieldatensatz mit den Stützstellendaten und interpolierten Daten.

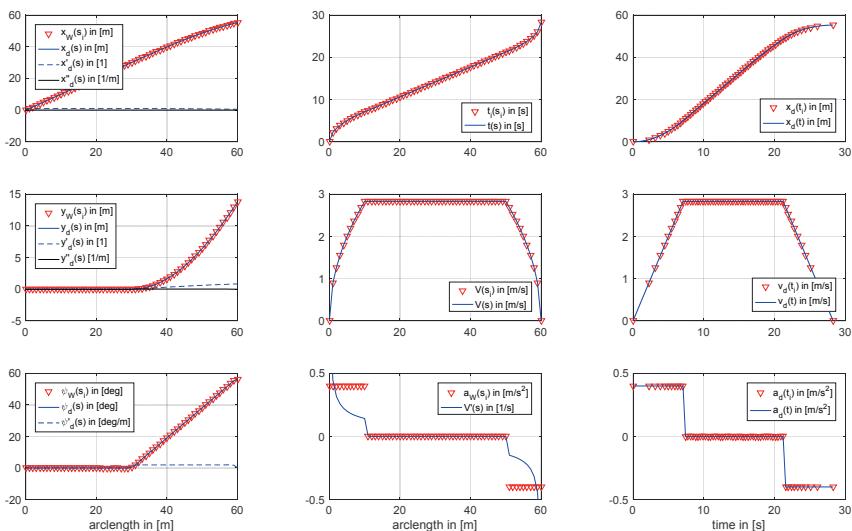


Fig. 5: Beispieldatensatz für eine Einfahrt in einen Kreis mit einer Vorausschau von 60 m mit Stillstand am Anfang und am Ende. Dargestellt sind die Daten an den Stützstellen im Abstand von 1 m und die interpolierten Größen aus dem Trajektoriengenerator

### 3.2 Flachheitsbasierte Vorsteuerung für die kinematische Bewegungssteuerung

Die flachheitsbasierte Vorsteuerung basiert auf dem kinematischen Modell (6). Als Stellgrößen werden die Bahngeschwindigkeit, der Schwimmwinkel und die Gierrate gewählt.

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\psi} \end{bmatrix} = \begin{bmatrix} v \cos(\psi + \beta) \\ v \sin(\psi + \beta) \\ \omega \end{bmatrix} = \begin{bmatrix} u_1 \cos(\psi + u_2) \\ u_1 \sin(\psi + u_2) \\ u_3 \end{bmatrix} \quad (6)$$

Das System (6) ist flach für die Ausgangsgrößen Position  $x$  und  $y$  sowie Gierwinkel  $\psi$ . Damit können die Vorsteuergrößen durch den flachen Ausgang und den entsprechenden Ableitungen bestimmt werden zu

$$\begin{bmatrix} u_1 \\ u_2 \\ u_3 \end{bmatrix} = \begin{bmatrix} v_d \\ \beta_d \\ \omega_d \end{bmatrix} = \begin{bmatrix} \sqrt{\dot{x}_d^2 + \dot{y}_d^2} \\ \arctan \frac{\dot{y}_d}{\dot{x}_d} - \psi_d \\ \dot{\psi}_d \end{bmatrix} = \begin{bmatrix} V(s) \sqrt{x_d'^2 + y_d'^2} \\ \arctan \frac{y_d'}{x_d'} - \psi_d \\ V(s) \dot{\psi}_d' \end{bmatrix} \quad (7)$$

Der Gierwinkel kann im Rahmen der Aktorbegrenzungen im Prinzip beliebig vorgegeben werden. Zwei Sonderfälle sind jedoch von besonderer Bedeutung. Dies betrifft eine Fahrt einerseits mit Gierwinkel Null und andererseits mit Schwimmwinkel Null, s. Fig. 6. Für den letzteren Fall muss der Gierwinkel aus den Positionsgrößen in der Form

$$\psi_d = \arctan \frac{y_d'}{x_d'} \quad (8)$$

bestimmt werden. Die Vorsteuerung der Gierrate ergibt sich damit nach (7) zu

$$\omega_d = V(s) \frac{x_d' y_d'' - x_d'' y_d'}{x_d'^2 + y_d'^2} \quad (9)$$

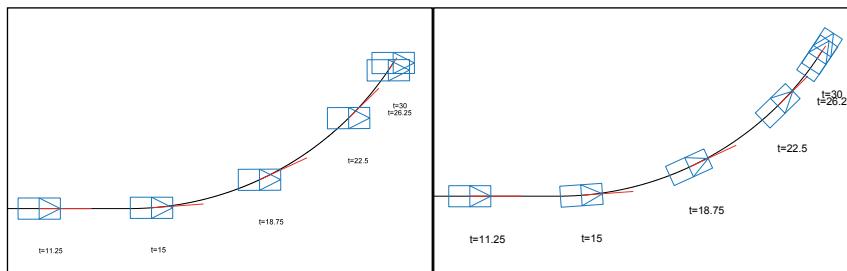


Fig. 6: Geregelte Fahrt mit Gierwinkel  $\psi = 0$  (links) und Schwimmwinkel  $\beta = 0$  (rechts). Das Geschwindigkeitsprofil entspricht dem aus Fig. 5, wobei die Geradeausfahrt in den ersten 10 s in den Bildern nicht dargestellt ist.

### 3.3 Zustandsregelung für die kinematische Bewegungssteuerung

Die Zustandsregelung soll den Abstand und die Ausrichtung zwischen dem Koordinatensystem im Fahrzeugschwerpunkt  $b$  und einem mit dem Sollpfad mitbewegten System  $f$  möglichst klein halten, siehe Fig. 7.

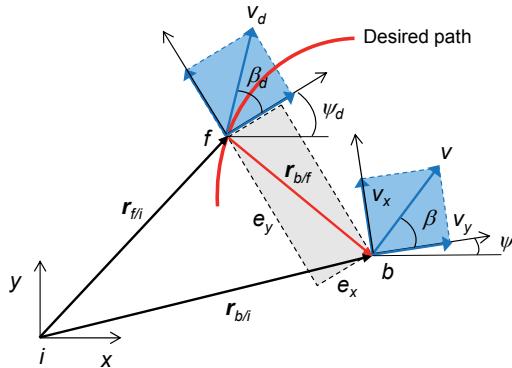


Fig. 7: Koordinatensysteme für die Verfolgung des Sollpfades (engl. desired path):  
Inertialsystem  $i$ , körperfestes System  $b$  und Sollpfadsystem  $f$ . Ziel der Bewegungssteuerung ist die Minimierung des Abstands  $r_{b/f}$  und der Ausrichtungsdifferenz  
 $e_\psi = \psi - \psi_d$

Die auszuregelnde Abweichung wird im Sollpfadsystem angegeben mit den Fehlerkoordinaten

$$\begin{bmatrix} e_x \\ e_y \\ e_\psi \end{bmatrix} = \begin{bmatrix} \cos \psi_d & \sin \psi_d & 0 \\ -\sin \psi_d & \cos \psi_d & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x - x_d \\ y - y_d \\ \psi - \psi_d \end{bmatrix} \quad (10)$$

Die Änderung der Fehlerkoordinaten ergibt sich durch Differenzierung von (10) nach der Zeit. Für die Ableitung des Vektors  $r_{b/f}$  werden alle Vektoren im Sollpfadsystem  $f$  dargestellt mit dem Zusammenhang

$$\frac{d}{dt} r_{b/f}^f = R_b^f(e_\psi) v_{b/i}^b - v_{f/i}^f - \omega_{f/i}^f \times r_{b/i}^f \quad (11)$$

In Komponentenform erhält man aus (11)

$$\begin{bmatrix} \dot{e}_x \\ \dot{e}_y \\ \dot{e}_\psi \end{bmatrix} = \begin{bmatrix} \cos e_\psi & -\sin e_\psi \\ \sin e_\psi & \cos e_\psi \end{bmatrix} \begin{bmatrix} v_x \\ v_y \end{bmatrix} - \begin{bmatrix} v_d \cos \beta_d \\ v_d \sin \beta_d \end{bmatrix} - \begin{bmatrix} 0 & -\omega_d \\ \omega_d & 0 \end{bmatrix} \begin{bmatrix} e_x \\ e_y \end{bmatrix} \quad (12)$$

Ersetzen der kartesischen Koordinaten  $v_x$  und  $v_y$  der Fahrzeuggeschwindigkeit durch Polarkoordinaten mit Betrag  $v$  und Winkel  $\beta$  und Zusammenfassung mit dem Orientierungsfehler ergibt das nichtlineare kinematische Fehlerequationsystem

$$\begin{bmatrix} \dot{e}_x \\ \dot{e}_y \\ \dot{e}_\psi \end{bmatrix} = \begin{bmatrix} v \cos(e_\psi + \beta) - v_d \cos \beta_d + \omega_d e_y \\ v \sin(e_\psi + \beta) - v_d \sin \beta_d - \omega_d e_x \\ \omega - \omega_d \end{bmatrix} \quad (13)$$

Das System (13) wird linearisiert um eine Geradeausfahrt auf der Sollbahn mit konstanter Geschwindigkeit  $v_{d0}$ . Man erhält das nachfolgende lineare zeitinvariante System (14), für das ein Zustandsregler ausgelegt werden kann.

$$\begin{bmatrix} \dot{e}_x \\ \dot{e}_y \\ \dot{e}_\psi \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & v_{d0} \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} e_x \\ e_y \\ e_\psi \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ 0 & v_{d0} & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} v_R \\ \beta_R \\ \omega_R \end{bmatrix} + \begin{bmatrix} -1 & 0 & 0 \\ 0 & -v_{d0} & 0 \\ 0 & 0 & -1 \end{bmatrix} \begin{bmatrix} v_d \\ \beta_d \\ \omega_d \end{bmatrix} \quad (14)$$

Der Entwurf einer linear-quadratischen Regelung (LQR) ergibt den Zustandsregler (15), der in der Längs- und Querbewegung entkoppelt ist. Die Vorsteuergrößen (7) werden wie üblich in dem Fehlersystem (14) als Störgrößen interpretiert und durch Aufschaltung kompensiert.

$$\begin{bmatrix} v_R \\ \beta_R \\ \omega_R \end{bmatrix} = - \begin{bmatrix} k_{11} & 0 & 0 \\ 0 & k_{22} & k_{23} \\ 0 & k_{32} & k_{33} \end{bmatrix} \begin{bmatrix} e_x \\ e_y \\ e_\psi \end{bmatrix} \quad (15)$$

Die Längsabweichung  $e_x$  wird nach (15) mit einem P-Regler ausgeregelt. Bessere Ergebnisse erhält man mit einem PI-Regler, der alternativ auch als Zustandsregler für das mit der Tangentialbeschleunigung  $a_d$  gestörte Fehlersystem (16) ausgelegt werden kann.

$$\begin{bmatrix} \dot{e}_x \\ \ddot{e}_x \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} e_x \\ \dot{e}_x \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} a_d + \begin{bmatrix} 0 \\ -1 \end{bmatrix} a_d \quad (16)$$

Die Reglerausgangsgröße  $a_d$  muss anschließend integriert werden, um  $v_R$  zu erhalten. Fig. 8 zeigt anhand der Fehlerkoordinaten für die Fahrmanöver aus Fig. 6, dass die Abweichungen zum Sollkurs ausreichend gering gehalten werden können.

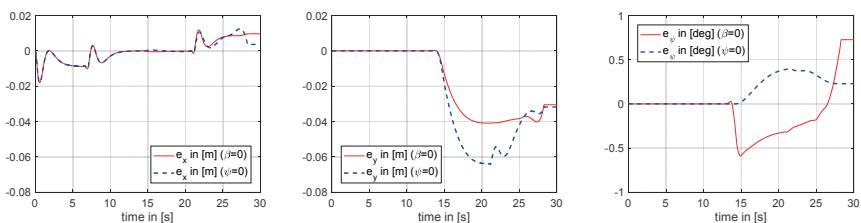


Fig. 8: Abweichungen des geregelten Fahrzeugs von der Sollbahn für die beiden Fahrmanöver aus Fig. 6

In Zukunft wäre auch eine Linearisierung von (13) um eine beliebige Sollbewegung denkbar, die auf ein lineares parameter-variables System führt. Für die Synthese von sog. Linear Pa-

rameter-Varying (LPV) Systemen stehen Methoden aus der robusten Regelung zur Verfügung, die auf linearen Matrix-Ungleichungen (Linear Matrix Inequalities, LMI) beruhen.

### 3.4 Exakte Linearisierung für die dynamische Bewegungssteuerung

Die dynamische Bewegungssteuerung wird ausgelegt mit der Methode der exakten Ein-/Ausgangs-Linearisierung auf der Basis der nichtlinearen eingangsaffinen Standardform

$$\dot{x} = f(x) + G(x)u_c \quad (17)$$

$$y = h(x) \quad (18)$$

Für das dynamische Einspurmodell ergibt sich die System- und Ausgangsgleichung (17) bzw. (18) mit den folgenden Vektoren und Matrizen zu

$$\begin{bmatrix} \dot{v}_x \\ \dot{v}_y \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} v_y \omega \\ -v_x \omega \\ 0 \end{bmatrix} + \begin{bmatrix} \frac{1}{m} & 0 & 0 \\ 0 & \frac{1}{m} & 0 \\ 0 & 0 & \frac{1}{J_z} \end{bmatrix} \begin{bmatrix} F_{x,c} \\ F_{y,c} \\ M_{z,c} \end{bmatrix} \quad (19)$$

$$\begin{bmatrix} v \\ \beta \\ \omega \end{bmatrix} = \begin{bmatrix} \sqrt{v_x^2 + v_y^2} \\ \arctan \frac{v_y}{v_x} \\ \omega \end{bmatrix} \quad (20)$$

Die Ausgangsgrößen  $y$  werden nach der Zeit abgeleitet, so lange bis sich schließlich in der  $r$ -ten Zeitableitung jeder Ausgangsgröße eine Eingangsgröße auf der rechten Seite der Gleichung explizit auftritt. Die Gesamtzahl der Ableitungen wird vektorieller relativer Grad genannt und muss kleiner oder höchstens gleich der Systemordnung sein, d.h. es muss hier gelten

$$r = r_1 + r_2 + r_3 \leq 3 \quad (21)$$

Das System (19) ist mit den Ausgangsgrößen (20) nach [9] flach und besitzt den vollen vektoriellen relativen Grad drei, weil alle einzelnen relativen Grade gleich eins sind. Fasst man die Ableitungen der Ausgangsgrößen zusammen im Vektor  $v$  der sog. Pseudosteuergrößen, so lassen sich die eigentlichen Steuergrößen  $u_c$  durch Inversion der sog. Entkopplungsmatrix  $A(x)$  bestimmen zu

$$v = b(x) + A(x)u_c \quad (22)$$

$$\rightarrow u_c = A^{-1}(x)(v - b(x)) \quad (23)$$

Die Elemente der Vektoren und Matrizen ergeben sich mit Hilfe der platzsparenden Schreibweise der Lie-Ableitungen als

$$v = \begin{bmatrix} y_1^{(r_1)} \\ y_2^{(r_2)} \\ y_3^{(r_3)} \end{bmatrix} = \begin{bmatrix} \dot{v} \\ \beta \\ \dot{\omega} \end{bmatrix}, \quad b(x) = \begin{bmatrix} L_f^{r_1} h_1(x) \\ L_f^{r_2} h_2(x) \\ L_f^{r_3} h_3(x) \end{bmatrix} = \begin{bmatrix} 0 \\ -\omega \\ 0 \end{bmatrix}, \quad (24)$$

$$\mathbf{A}(\mathbf{x}) = \begin{bmatrix} L_{g_1} L_f^{r_1-1} h_1(\mathbf{x}) & L_{g_2} L_f^{r_1-1} h_1(\mathbf{x}) & L_{g_3} L_f^{r_1-1} h_1(\mathbf{x}) \\ L_{g_1} L_f^{r_2-1} h_2(\mathbf{x}) & L_{g_2} L_f^{r_2-1} h_2(\mathbf{x}) & L_{g_3} L_f^{r_2-1} h_2(\mathbf{x}) \\ L_{g_1} L_f^{r_3-1} h_3(\mathbf{x}) & L_{g_2} L_f^{r_3-1} h_3(\mathbf{x}) & L_{g_3} L_f^{r_3-1} h_3(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} \frac{v_x}{m\sqrt{v_x^2+v_y^2}} & \frac{v_y}{m\sqrt{v_x^2+v_y^2}} & 0 \\ -\frac{v_y}{m(v_x^2+v_y^2)} & \frac{v_x}{m(v_x^2+v_y^2)} & 0 \\ 0 & 0 & \frac{1}{J_z} \end{bmatrix} \quad (25)$$

Der vektorielle relative Grad (21) sichert zwar die Existenz der inversen Entkopplungsmatrix, jedoch ist aus den Nennern in (25) ersichtlich, dass der Stillstand Probleme bereitet. Es werden daher die Zustandsgrößen durch die flachen Ausgangsgrößen ersetzt. Mit Hilfe der Inversion

$$\mathbf{x} = \mathbf{h}^{-1}(\mathbf{y}) = \begin{bmatrix} v \cos \beta \\ v \sin \beta \\ \omega \end{bmatrix} \quad (26)$$

und durch Ersetzen der Zustandsgrößen ergibt sich eine inverse Entkopplungsmatrix, die auch für  $v=0$  definiert ist, als

$$\mathbf{A}^{-1}(\mathbf{x}) = \begin{bmatrix} \frac{mv_x}{\sqrt{v_x^2+v_y^2}} & -mv_y & 0 \\ \frac{mv_y}{\sqrt{v_x^2+v_y^2}} & mv_x & 0 \\ 0 & 0 & J_z \end{bmatrix} = \begin{bmatrix} m \cos \beta & -mv \sin \beta & 0 \\ m \sin \beta & mv \cos \beta & 0 \\ 0 & 0 & J_z \end{bmatrix} \quad (27)$$

Das System ist nach der Definition in [1] proxim steuerbar, d.h. es kann nicht beliebigen vorgegebenen Trajektorien folgen, weil es aus dem Stillstand nicht in alle Richtungen starten kann. Die Pseudosteuergrößen setzen sich für die Trajektorienfolgeregelung zusammen aus den Ableitungen des Referenzverlaufs für die Ausgangsgrößen und einer linearen Rückführung des Regelfehlers  $\mathbf{e}$ , d.h. es ist

$$\mathbf{v} = \dot{\mathbf{y}}_c - \mathbf{K}\mathbf{e} \quad (28)$$

mit den Reglerverstärkungen und dem Regelfehler

$$\mathbf{R} = \text{diag}(K_v, K_\beta, K_\omega), \quad \mathbf{e} = \mathbf{y} - \mathbf{y}_c \quad (29)$$

Die Steuergrößen lassen sich wie in [10] vorgeschlagen aufspalten in einen Anteil der Vorsteuerung und einen Anteil zur asymptotischen Stabilisierung, d.h.

$$\mathbf{u}_c = \mathbf{u}_{FF} + \mathbf{u}_{FB} = \mathbf{A}^{-1}(\mathbf{x})(\dot{\mathbf{y}}_c - \mathbf{b}(\mathbf{x})) + \mathbf{A}^{-1}(\mathbf{x})\mathbf{K}(\mathbf{y}_c - \mathbf{y}) \quad (30)$$

wobei die Vorsteuerung hier entlang der Referenztrajektorie gebildet wird. Die dynamische Bewegungssteuerung besteht somit aus den beiden Anteilen

$$\mathbf{u}_{FF} = \begin{bmatrix} F_{x,d} \\ F_{y,d} \\ M_{z,d} \end{bmatrix} = \begin{bmatrix} m(\dot{v}_c \cos \beta_c - v_c(\dot{\beta}_c + \omega_c) \sin \beta_c) \\ m(\dot{v}_c \sin \beta_c + v_c(\dot{\beta}_c + \omega_c) \cos \beta_c) \\ J_z \dot{\omega}_c \end{bmatrix} \quad (31)$$

$$\mathbf{u}_{FB} = \begin{bmatrix} F_{x,R} \\ F_{y,R} \\ M_{z,R} \end{bmatrix} = \begin{bmatrix} m(K_v(v_c - v) \cos \beta_c - v_c K_\beta(\beta_c - \beta) \sin \beta_c) \\ m(K_v(v_c - v) \sin \beta_c + v_c K_\beta(\beta_c - \beta) \cos \beta_c) \\ J_z K_\omega(\omega_c - \omega) \end{bmatrix} \quad (32)$$

In Fig. 9 sind als Reaktion auf die Kräfte die Längs-, Quer- und Gierbeschleunigung für die Fahrmanöver aus Fig. 6 dargestellt. Deutlich zu erkennen sind die Unterschiede zwischen beiden Manövern bei der Einfahrt in den Kreis ab ca. 12 s, die die Passagiere auch entsprechend verschieden wahrnehmen dürften. Hierzu sind weitere Untersuchungen mit Probanden nötig.

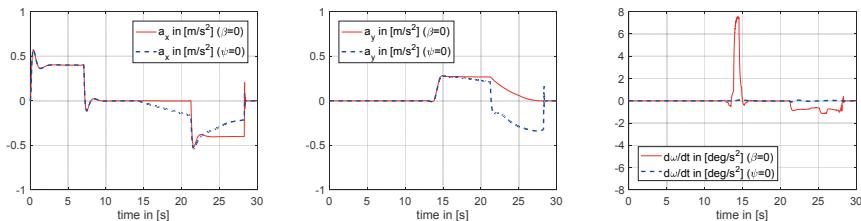


Fig. 9: Längs-, Quer- und Gierbeschleunigung im Schwerpunkt des Fahrzeugs für die Fahrmanöver aus Fig. 6

#### 4 Verteilung der Stellgrößen (Control Allocation)

Die Steuerung der dynamischen Bewegung geschieht über das Steuergesetz (30) mittels mechanischer Kräfte und Momente. In der nachfolgenden Stufe der Bewegungssteuerung werden elektro-mechanische bzw. elektro-hydraulische Aktuatoren eingesetzt, um die Stärke und Richtung der Kräfte gemäß den Vorgaben zu beeinflussen. Für den CUbE sind mehr Aktuatoren verbaut, als für die eigentliche Regelungsaufgabe notwendig sind, d.h. das System ist überaktuiert. Damit wird ein intelligenter Verteilungsalgorithmus notwendig, der aber auch mehrere Vorteile mit sich bringt:

- Ausnutzung von Redundanz, um Anforderung bzgl. Fehlertoleranz und Rekonfiguration zu erfüllen
- Ausgleich von Begrenzungen in Amplitude und Stellgeschwindigkeit bei den Aktuatoren
- Minimierung von Energieverbrauch oder der Abnutzung von Bauteilen

Eine Übersicht über gängige Verteilungsalgorithmen bieten die Literaturstellen [4] und [7]. Für die Aufteilung der kommandierten Gesamtkräfte  $F_{x,c}$  und  $F_{y,c}$  und des Giermoments  $M_{z,c}$  auf die Radkräfte und letztlich auf die Aktuatoren wird folgendes Modell verwendet

$$\mathbf{u}_c = \mathbf{T}[F_{Ef} \quad F_{Bf} \quad F_{Sf} \quad F_{Er} \quad F_{Br} \quad F_{Sr}]^T = \mathbf{T}(\mathbf{B}_u \mathbf{u} + \mathbf{b}) \quad (33)$$

mit den Stellgrößen E-Motormoment  $M_E$ , Reibungsbremsmoment  $M_B$  und Lenkwinkel  $\delta$  jeweils an Vorder- und Hinterachse sowie den weiteren Matrizen und Vektoren

$$\mathbf{u} = [M_{Ef,c} \ M_{Bf,c} \ \delta_{f,c} \ M_{Er,c} \ M_{Br,c} \ \delta_{r,c}]^T \quad (34)$$

$$\mathbf{T} = \begin{bmatrix} \cos \delta_f & \cos \delta_f & -\sin \delta_f & \cos \delta_r & \cos \square_f & -\sin \square_f \\ \sin \square_f & \sin \square_f & \cos \delta_f & \sin \square_f & \sin \square_f & \cos \delta_r \\ \square_f \sin \square_f & \square_f \sin \square_f & l_f \cos \delta_f & -\square_f \sin \square_f & -\square_f \sin \square_f & -\square_f \cos \square_f \end{bmatrix} \quad (35)$$

$$\mathbf{B}_u = \text{diag} \left( \frac{1}{r_R}, \frac{1}{r_R}, C_f, \frac{1}{r_R}, \frac{1}{r_R}, C_r \right) \quad (36)$$

$$\mathbf{b} = \begin{bmatrix} 0 & 0 & C_f (-\beta_c - \frac{l_f}{v_c} \omega_c) & 0 & 0 & C_r (-\beta_c + \frac{l_r}{v_c} \omega_c) \end{bmatrix}^T \quad (37)$$

Die Matrix  $\mathbf{B}_u$  enthält die Fahrzeugparameter Radradius  $r_R$  und Schräglauftiefigkeit  $C_{fr}$  für die vereinfachend als linear angenommenen Reifenkräfte. Die Lenkwinkel in der Transformationsmatrix  $\mathbf{T}$  sind hier die kommandierten Lenkwinkel aus dem vorhergehenden Rechenschritt. Zur Berechnung des Vektors  $\mathbf{b}$  muss die kommandierte Geschwindigkeit auf einen Wert ungleich Null beschränkt werden.

#### 4.1 Stellgrößenverteilung ohne Berücksichtigung von Nebenbedingungen

Eine einfache Möglichkeit, die Stellgrößen zu verteilen, ist die Auflösung der Gl. (33) nach  $\mathbf{u}$  über die Moore-Penrose Pseudoinverse. Hier wird eine Variante mit der Gewichtung der Stellgrößen über die diagonale Gewichtungsmatrix  $\mathbf{W}_u$  vorgeschlagen. Die Berechnungsvorschrift für die Stellgrößen hat damit die Form

$$\mathbf{u} = \mathbf{B}_u^{-1} \mathbf{W}_u^{-1} \mathbf{T}^T (\mathbf{T} \mathbf{W}_u^{-1} \mathbf{T}^T)^{-1} (\mathbf{u}_c - \mathbf{T} \mathbf{b}) \quad (38)$$

Die einzelnen Gewichte in der Gewichtungsmatrix können während des Betriebs angepasst werden, um die eingangs erwähnten Vorteile zumindest teilweise auszuschöpfen. Dabei bewirkt eine geringe Gewichtung die Berücksichtigung der entsprechenden Stellgröße und umgekehrt blendet eine hohe Gewichtung sie aus, s. Fig. 10. Ein Nachteil der Methode ist, dass Zwangsbedingungen, wie z.B. Begrenzungen, nicht berücksichtigt werden können.

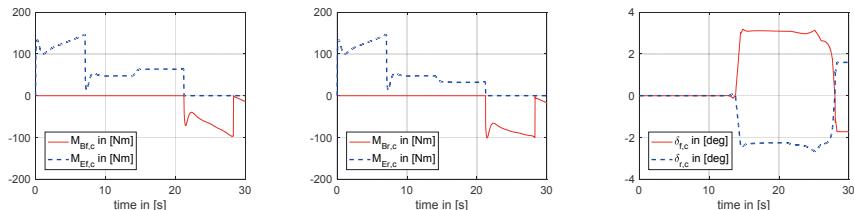


Fig. 10: Stellgrößenverteilung ohne Nebenbedingungen mit Pseudoinverse für das Fahrma-  
növer Schwimmwinkel  $\beta=0$ . Umblenden zwischen E-Motoren und Reibungsbremsen  
bei Verzögerungsanforderungen von  $F_{x,c} < 0$  durch Umschalten der Gewichtungs-  
faktoren.

#### 4.2 Stellgrößenverteilung mit Berücksichtigung von Nebenbedingungen

Die volle Ausnutzung der Vorteile kann über eine on-line Optimierung erfolgen. Aufgrund eines Kompromisses zwischen Leistungsfähigkeit und Realisierbarkeit wird hier die konvexe quadratische Optimierung mit einer quadratischen Gütfunktion  $J$  und ausschließlich linearen Nebenbedingungen gewählt. Die Optimierungsaufgabe lautet:

$$\min_{\mathbf{u}, \mathbf{s}} J(\mathbf{u}, \mathbf{s}) = \frac{1}{2} [\mathbf{u}^T \quad \mathbf{s}^T] \mathbf{H} [\mathbf{u} \quad \mathbf{s}] \quad (39)$$

unter Berücksichtigung der Nebenbedingungen

$$[\mathbf{T} \mathbf{B}_u \quad -\mathbf{I}] \begin{bmatrix} \mathbf{u} \\ \mathbf{s} \end{bmatrix} = \mathbf{u}_c - \mathbf{T} \mathbf{b} \quad (40)$$

$$\begin{bmatrix} \mathbf{I} & \mathbf{0} \\ -\mathbf{I} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \\ -\mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{u} \\ \mathbf{s} \end{bmatrix} \leq \begin{bmatrix} \mathbf{u}_{max} \\ -\mathbf{u}_{min} \\ \Delta \mathbf{u}_{max} + \mathbf{u}_{-1} \\ -\Delta \mathbf{u}_{max} - \mathbf{u}_{-1} \end{bmatrix} \quad (41)$$

Mit dem Einsatz von Schlupfvariablen  $\mathbf{s}$  (engl.: slack variables) existiert immer eine Lösung unter Einhaltung der Gleichheitsnebenbedingungen. Die Matrix  $\mathbf{H}$  setzt sich zusammen aus den Gewichtungen der Stellgrößen und Gewichtungen zur Bestrafung der Schlupfvariablen, d.h.

$$\mathbf{H} = \text{diag}(\mathbf{W}_u, \mathbf{W}_s) \quad (42)$$

Die Ungleichungsnebenbedingungen enthalten Begrenzungen für Amplitude und Stellgeschwindigkeit der jeweiligen Aktoren, wobei mit  $\mathbf{u}_{k-1}$  die Stellgrößen aus dem vorherigen Rechenschritt bezeichnet werden. Fig. 11 zeigt exemplarisch die Stellgrößenverteilung mit Nebenbedingungen und eine Rekonfiguration im Fehlerfall. Für die Optimierung wurde die Matlab Funktion quadprog [12] verwendet. Die Optimierung sorgt für den Einsatz der Reibungsbremsen, wenn die Bremswirkung der E-Motoren durch Amplitudenbegrenzung oder begrenzte negative Stellgeschwindigkeiten zu klein ist.

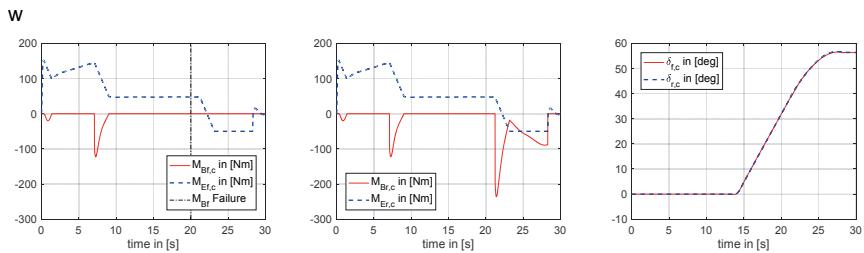


Fig. 11: Stellgrößenverteilung mit Nebenbedingungen für das Fahrmanöver Gierwinkel  $\psi=0$ .

Berücksichtigung von Begrenzungen der E-Motoren ( $M_{E,min} = -50 \text{ Nm}$ ,  $\Delta M_{E,min} = -50 \text{ Nm/s}$ ) und Reibungsbremsen ( $M_{Br,max} = 0 \text{ Nm}$ ) über die Ungleichheitsnebenbedingungen. Rekonfiguration nach Ausfall der Reibungsbremse an der Vorderachse durch Neuverteilung auf die Hinterachse mittels Heraufgewichtung ab dem Fehlerzeitpunkt  $t=20 \text{ s}$  mit  $W_{\nu2,2} = 1e6$ .

#### 4.3 Stellgrößenverteilung mit Berücksichtigung der Energieeffizienz des Antriebs

Die Energieeffizienz der Bewegungssteuerung ist zunehmend Gegenstand aktueller Forschung, siehe z.B. [2] und [4]. Für eine optimale Aufteilung der Momente der E-Motoren unter energetischen Gesichtspunkten werden die motorischen und generatorischen Wirkungsgrade  $\eta_{mot}$  bzw.  $\eta_{gen}$  benötigt. Sie sind nichtlinear abhängig vom aktuellen Moment und der Drehzahl des E-Motors und liegen i.d.R nur als Kennfelder vor. Für die Drehzahl wird hier näherungsweise die Raddrehzahl  $\omega_W$  verwendet. Die Leistungsverluste können dann wie folgt bestimmt werden:

$$P_{loss} = \begin{cases} \frac{M_E \omega_W}{\eta_{mot}(M_E, \omega_W)} - M_E \omega_W, & M_E \geq 0 \\ |M_E| \omega_W - |M_E| \omega_W \eta_{gen}(M_E, \omega_W), & M_E < 0 \end{cases} \quad (43)$$

Nach [3] und [13] beschränkt sich das Optimierungsproblem auf die Bestimmung einer optimalen Momentenverteilung  $\Delta M_E$  ausgehend von einem Arbeitspunkt  $M_{E0}$ . Die Momente an Vorder- und Hinterachse ergeben sich damit zu

$$M_{E_f,c} = M_{E0} + \Delta M_E \quad (44)$$

$$M_{E_r,c} = M_{E0} - \Delta M_E \quad (45)$$

Das Moment  $M_{E0}$  bestimmt sich aus der Gesamtanforderung  $F_{x,c}$  abzüglich der Brems- und Seitenkraftanteile, d.h.

$$M_{E0} = \frac{r_R(F_{x,c} - F_{Bf} \cos \delta_f - F_{Br} \cos \delta_r + F_{Sf} \sin \delta_f - F_{Sr} \sin \delta_r)}{W_f \cos \delta_f + (1 - W_f) \cos \delta_r} \quad (46)$$

Für den Verteilungsfaktor  $W_f$  wird der Wert 0.5 gewählt, d.h. die Gesamtanforderung wird je zur Hälfte auf die Achsen aufgeteilt. Die hochgradig nichtlinearen Verlustleistungsterme aus Gl. (43) müssen für die quadratische Programmierung im Arbeitspunkt (46) linearisiert werden. Man erhält dann für den Motorbetrieb folgendes, den Abschnitt 4.2 ergänzendes Optimierungsproblem:

$$\begin{aligned} \min_{\Delta M_E} J_P(\Delta M_E) = & \frac{1}{2} \left( \nabla^2 P_{loss,f} \Big|_{M_E=M_{E0}} + \nabla^2 P_{loss,r} \Big|_{M_E=M_{E0}} \right) \Delta M_E^2 + \\ & + \left( \nabla P_{loss,f} \Big|_{M_E=M_{E0}} - \nabla P_{loss,r} \Big|_{M_E=M_{E0}} \right) \Delta M_E \end{aligned} \quad (47)$$

unter Berücksichtigung der Nebenbedingungen

$$\begin{bmatrix} 1 \\ -1 \end{bmatrix} \Delta M_E \leq \begin{bmatrix} M_{E0} \\ M_{E0} \end{bmatrix} \quad (48)$$

Im Generatorbetrieb fließt die Verlustleistung in die Batterie. Damit liegt ein Maximierungsproblem vor, dass aber durch Verwendung der negativen Kostenfunktion wieder in ein Minimierungsproblem umgewandelt werden kann. Da keine Wirkungsgradkennfelder zur Verfügung standen, muss auf Simulationsergebnisse leider verzichtet werden.

## 5 Ausblick

Die vorgestellte Bewegungssteuerung ist nicht auf zwei Achsen beschränkt. Sie kann leicht erweitert werden auf weitere Achsen sowie radindividuelle Aktoren für Antrieb, Bremse und Lenkung. Hierzu muss lediglich die Stellgrößenverteilung angepasst werden, Regler- und Vorsteuerungen bleiben gleich. Die flexible Wahl der Orientierung des autonomen Fahrzeugs erlaubt die Einhaltung kurzer und schmaler Wege ohne Überhang in benachbarte Fahrspuren. Dies erhöht die Sicherheit und bietet Potenzial zur Vermeidung von Kollisionen.

## Literatur

- [1] Adamy, J.: Nichtlineare Systeme und Regelungen. 3. Aufl. Springer, Berlin, 2018
- [2] Brembeck, J.: Model Based Energy Management and State Estimation for the Robotic Electric Vehicle ROboMObil . Dissertation, Technische Universität München, 2018
- [3] Dizqah, A.M.; Blundell, M.; Vantsevic, V.V.; Kanarachos, S.; Ballard, B.: Fast Energy-Efficient Torque Distribution Amongst Multiple Drivetrains, In: Proc. 19<sup>th</sup> International & 14<sup>th</sup> European-African Regional Conference of the ISTVS, Budapest, 2017
- [4] Durham, W.; Bordignon, K.A.; Beck, R.: Aircraft Control Allocation, Wiley, West Sussex, 2017
- [4] Eckert, M.: Energieoptimale Fahrdynamikregelung mehrmotoriger Elektrofahrzeuge. Dissertation, Karlsruher Institut für Technologie, 2014
- [6] Heimann, P.: Ein Beitrag zur Modellierung des Reifenverhaltens bei geringen Geschwindigkeiten. Dissertation, Universität Stuttgart, 2017
- [7] Johansen, T.A.; Fossen, T.I.: Control allocation – A survey. In: Automatica 49, 2013, pp. 1087-1103
- [8] Lauxmann, R.; Eckert, A.; Raste, T.; Hohm, A.: Von assistierten Sicherheitsfunktionen zu sicheren und visionären Mobilitätskonzepten. ATZ Jubiläumsausgabe 120 Jahre ATZ, 2018, S. 62-66
- [9] Orend, R.: Modelling and Control of a Vehicle with Single-Wheel Chassis Actuators. In: Proc. of 16<sup>th</sup> IFAC World Congress, Prague, 2005
- [10] Röbenack, K.: Nichtlineare Regelungssysteme. Springer, Berlin, 2017
- [11] Roland Berger: A CEO agenda for the (r)evolution of the automotive ecosystem. Think Act 15, 2016
- [12] The MathWorks.: Optimization Toolbox Users Guide, Matlab, 2018
- [13] Wu, D.; Ding, H.; Du, C.: Dynamics Characteristics Analysis and Control of FWID EV. Int. Journal of Automotive Technology, Vol. 19, No. 1, 2018, pp. 135-146

# Energy-Optimal Adaptive Cruise Control based on Model Predictive Control in the Real Driving Emissions Test Cycle

**Yanzhao Jia, Ulrich Schwarz,**

Electrification system R&D, DENSO Automotive Deutschland GmbH,  
Wegberg;

**Daniel Görge,**

Electromobility Research Group, Technische Universität Kaiserslautern

## Abstract

This paper presents energy-optimal adaptive cruise control (EACC) based on model predictive control (MPC), which online plans an energy-optimal speed trajectory for the controlled host car and optimally adjusts the inter-vehicle distance between the host car and its preceding car through exploiting the information about the preceding car's future speed, as well as the road topography and the speed limit ahead. For online optimal control, MPC-based EACC is formulated as a linearly constrained quadratic programming (QP) problem. To deal with the non-convexity of the power consumption map, this paper proposes a method to calculate the coefficients of the power approximation function that vary with the operational region of the engine. The performance of MPC-based EACC is analysed through simulation in a real driving emissions (RDE) cycle, which is built up with recorded speed data in different driving conditions. Furthermore, the influence of the future speed information of the preceding car on EACC is investigated in the paper.

## 1 Introduction

In recent years, the advanced driving assistance systems (ADAS) provided by automotive manufacturers and suppliers target not only on safer driving but also on more eco-driving [1] [2] [3]. With such development goals, the new concept of energy-optimal adaptive cruise control (EACC) is proposed, which uses various surrounding information, such as the road topography, speed limit and the predicted future speed of the preceding car, to online plan the optimal speed trajectory for the host car so that the host car consumes less energy for finishing a trip, compared to its preceding car [4].

Besides the main goal of saving the driving energy, EACC has other control objectives at the same time: a). the host car keeps following its preceding car; b). guarantee the minimum safe

inter-vehicle distance, which depends on the speed of the host car; c). reduce the oscillation of the driving force for better driving comfort. For achieving the multiple control objectives, model predictive control (MPC) is proposed in several recent works as a promising method [5] [6]. As nonlinear MPC can be harder to implement on an embedded system for online control due to the demanding computation time, MPC-based speed control is formulated as a linearly constrained quadratic programming (QP) problem [7]. However, the power consumption map of a vehicle with an internal consumption engine (ICE) cannot be perfectly represented by a single quadratic function [8]. One contribution of this paper is the proposal of making more accurate power approximation with multiple quadratic functions. In order to investigate the benefit and performance of EACC in various daily driving situations, a representative test cycle of 87.3 km is created in this work through using recorded driving data on different roads, which meets the European real driving emissions (RDE) test regulations. With simulation in the test cycle, the driving behaviour of the host car controlled by EACC is analysed and compared to its preceding car. It is also revealed in this paper how the information about the preceding car's future speed affects the performance of the controlled host car.

This paper is organized as follows: Section 2 presents the modelling of the vehicles in time domain. The control scheme and the design of MPC-based EACC are explained in Section 3. Afterwards, the simulation results provided in Section 4 give insight into the performance of EACC in different driving situations and demonstrate the impact of future information on fuel reduction. Finally, conclusions and the future work are given in Section 5.

## 2 Modelling of Vehicle Dynamics in Time Domain

For discrete-time control, the inter-vehicle distance  $d$  and the host vehicle speed  $v_h$  at each control step  $i$  is calculated from

$$d_{i+1} = d_i + \left( \frac{v_{p,i+1} + v_{p,i+1}}{2} - \frac{v_{h,i} + v_{h,i+1}}{2} \right) \Delta_t \quad (1)$$

$$v_{h,i+1} = v_{h,i} + \frac{\Delta_t}{m_{eq}} (F_{t,i} - F_{b,i} - F_{resist,i}) \quad (2)$$

where  $v_p$  is the speed of the preceding car and  $\Delta_t$  is the sample time, which is set as 0.2 sec in the simulation of this work. In (2), the equivalent vehicle mass  $m_{eq}$  includes the vehicle mass  $m_v$  and the effect of all rotational mass of the powertrain. The traction force and the braking force, which are provided by the powertrain and act on the wheels, are denoted as  $F_t$  and  $F_b$  separately. The total driving resistance force  $F_{resist}$  that includes three parts [9] is calculated from

$$F_{\text{resist},i} = F_{\text{roll},i} + F_{\text{grad},i} + F_{\text{air},i} \quad (3a)$$

$$F_{\text{roll},i} = m_v g c_r \cos \theta_i \quad (3b)$$

$$F_{\text{grad},i} = m_v g \sin \theta_i \quad (3c)$$

$$F_{\text{air},i} = \frac{1}{2} \rho_a A_f c_a v_{h,i}^2 \quad (3d)$$

In (3),  $F_{\text{roll}}$  is the rolling resistance which is calculated with the vehicle mass  $m_v$ , gravitational acceleration  $g$ , wheel rolling resistance coefficient  $c_r$  and the road gradient  $\theta$ .  $F_{\text{grad}}$  represents the road gradient resistance. The aerodynamic resistance  $F_{\text{air},i}$  is modelled as a function of  $v_h$  with the drag coefficient  $c_a$ , frontal area  $A_f$  and the air density  $\rho_a$ .

### 3 Design of MPC-based EACC

In this Section, the details in the problem formulation of MPC-based EACC are provided, in order to explain how the multiple control objectives that are introduced in Section 1 are quantified with mathematical functions in an accurate way.

#### 3.1 Power map approximation

The power consumption  $P$  of an ICE car is non-linear mapping  $\varphi$  of the vehicle speed  $v$  and the traction force  $F_t$ , i.e.,  $\varphi: F_t \times v \rightarrow P$ . The red points in Fig. 1 are the measurement data of power consumption. As the main control objective of EACC is to minimize the energy for driving, namely to minimize the sum of  $P$  multiplied by the sample time over the period of a trip, the power consumption needs to be calculated with a mathematical function. In the previous work [6], the power consumption has been approximated by one quadratic function, i.e.,

$$\varphi \approx f(F_t, v) = p_{00} + p_{01}F_t + p_{10}v + p_{02}F_t^2 + p_{20}v^2 + p_{11}vF_t \quad (4)$$

Fig. 1 shows the real power consumption map of the ICE car for a specific gear and the approximated power consumption map with (4). It is observable that the two maps are not identical. The approximation error is relatively larger in some areas that are encircled with the dash lines. For instance, the real power consumption is zero when the traction force is zero, as the vehicle has a coasting function with the clutch being open. However, the approximated power does not equal to zero in this situation which results in the approximation error in area A, as shown in Fig. 1. To address this inaccuracy in power approximation, the single approximation function is replaced with multiple functions which target on precise approximation of each local area.

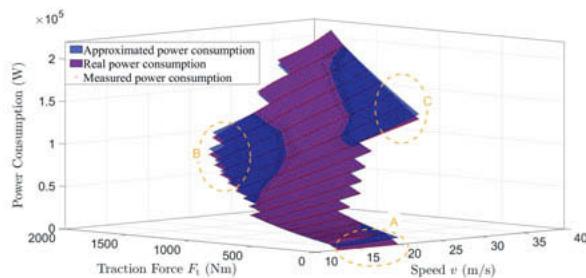


Fig. 1: Power consumption map and approximated map with a single convex function

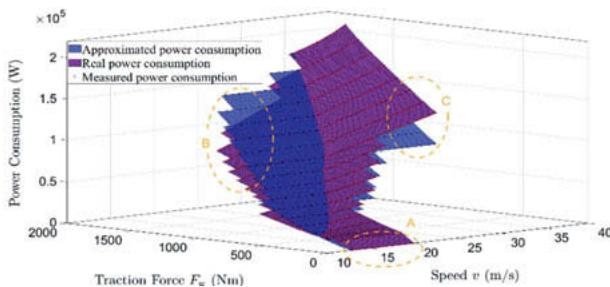


Fig. 2: Approximation of power consumption with a bias towards the area of traction force zero

With being biased towards the area in which the traction force is zero, an additional constraint  $f(0, v) = p_{00} + p_{10}v + p_{20}v^2 = 0$  is added so that the power approximation around the area A becomes more accurate. Fig. 2 shows that the new approximation result, which has higher accuracy in the area of small traction force (i.e., area A), at the expense of lower approximation accuracy in the area of B and C.

In order to create multiple functions which focus on the approximation of different areas, 20 points, which are named biased points, are picked up from the measurement points of power consumption, as shown in Fig. 3. The coordinates of the biased point is named  $[v_{b*}, F_{b*}]^T$ .

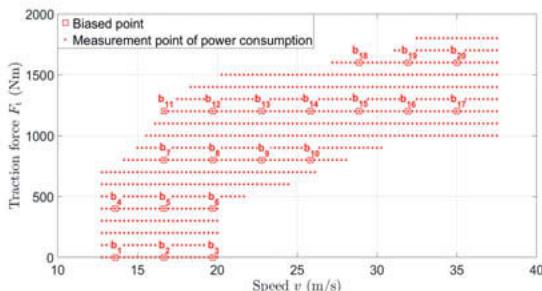


Fig. 3: Selection of the biased points for biased approximation

After the selection of the points for making the biased power approximation, the coefficients  $p_{**}$  of the approximation function  $f(F_{t,m}, v_n)$  are calculated through solving an optimization problem for each bias point  $b$ . The mathematical formulation of the optimization problem is defined by

$$\min_{p_{00} \dots p_{11}} \sum_{m=1}^M \sum_{n=1}^N \left( W_b(F_{t,m}, v_n) * f(F_{t,m}, v_n) - \varphi(F_{t,m}, v_n) \right)^2 \quad (5a)$$

$$\text{Where } W_b(F_t, v) = e^{-\frac{1}{2\sigma} \| [F_t, v]^T - b \|_2} \quad (5b)$$

$$f(F_t, v) = p_{00} + p_{01}F_t + p_{10}v + p_{02}F_t^2 + p_{20}v^2 + p_{11}vF_t \quad (5c)$$

$$\text{s.t. } A = \begin{bmatrix} 2p_{02} & p_{11} \\ p_{11} & 2p_{20} \end{bmatrix} \geq 0 \quad (5d)$$

The constraint (5d) ensures the approximation function (5c) is convex. The weighting factor  $W_b$  is assigned to each measurement point of the power consumption  $[F_t, v]^T$ . With (5b), the value of  $W_b$  is decided by the distance between the measurement point and  $b$ . As illustrated in Fig. 4, the shorter distance between the measurement point and the biased point  $b$ , the larger value the weighting factor  $W_b$  has. This means that making an accurate power approximation for the measurement points which are near to the biased points has a higher priority over those points that are far away from the biased point.

In order to quantify the accuracy of the power approximation, the percent error, which is defined as the ratio between the approximation error and the measured power consumption value, is calculated. Fig. 5 shows the percent error of two biased approximations. It is noticeable that the power approximation in the operation area around the biased point is more accurate than the approximation in other areas.

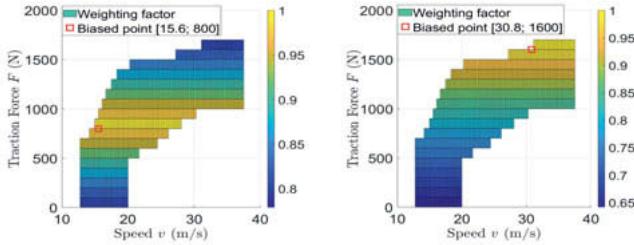
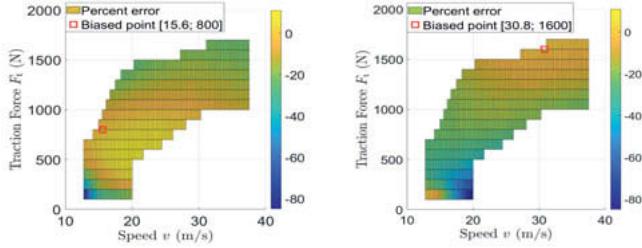
Fig. 4. Weighting factor  $W_b$  for two different biased points

Fig. 5: Percent error of power approximation with two biased approximation functions

### 3.2 MPC problem formulation

The mathematical formulation of the MPC problem with control horizon  $H$  is defined by

$$\min_{F_{t,i}, F_{b,i}} \sum_{i=k}^{k+H-1} f(F_{t,i}, v_{h,i}) + w_1 \delta_1^2 + w_2 \delta_2^2 + w_3 F_{b,i}^2 \quad (6a)$$

$$\text{s.t.} \quad (1), \quad (2),$$

$$d_{i+1} \geq d_{\min,0} + h_{\min} v_{h,i+1} \quad (6b)$$

$$d_{i+1} \leq d_{\min,0} + h_{\text{follow}} v_{h,i+1} + \delta_{1,i+1} \quad (6c)$$

$$0 \leq F_{t,i} \leq a_{10} + a_{11} v_{h,i} \quad (6d)$$

$$F_{t,i} \leq a_{20} + a_{21} v_{h,i} \quad (6e)$$

$$F_{t,i} \leq a_{30} + a_{31} v_{h,i} \quad (6f)$$

$$0 \leq F_{b,i} \leq \Delta F_{\text{brake,max}} \quad (6g)$$

$$0 \leq v_{h,i+1} \leq v_{\max,i+1} \quad (6h)$$

$$|F_{t,i} - F_{t,i-1}| \leq \Delta F_{t,\max} + \delta_{2,i} \quad (6i)$$

The cost function of the control is defined with (6a), which consists of four items. The first item approximates the power consumption, which has been introduced in Subsection 3.1. If there were only the first item, the controlled host vehicle would have no motivation to move and will

lose the tracking of its preceding car, as  $f(F_{t,i}, v_{h,i})$  is minimized when the traction force  $F_t$  is zero. In order to provide the host car an incentive to drive so that it follows its preceding car, the second item of the control cost is added through introducing the slack variable  $\delta_1$ . As depicted in Fig. 6, the value of  $\delta_1$  increases when the host vehicle is outside of the zone of car following, which is defined as the product of the host car speed  $v_h$  multiplied by the factor  $h_{\text{follow}}$  and plus the constant  $d_{\min,0}$ . The soft constraint (6c) explains how the slack variable  $\delta_1$  varies with  $d$ . In addition to (6c), the hard constraint (6b) is added to ensure the driving safety by restricting the minimum inter-vehicle distance, which is also shown in Fig. 6. The third cost item  $\delta_2$ , which is defined with (6i), penalizes the oscillation in the traction force between two consecutive control steps. Being formulated as a square of the braking force  $F_b$ , the last cost item in (6a) is introduced to reduce the use of the mechanical braking when it is not required for driving safety, as the kinetic energy is dissipated through mechanical braking. The constraints (6d)-(6f), where  $a_{**}$  are constants, define the feasible traction force. Similarly, the braking force is limited by (6g). The constraint (6h) restricts the maximum vehicle speed according to the speed limit.

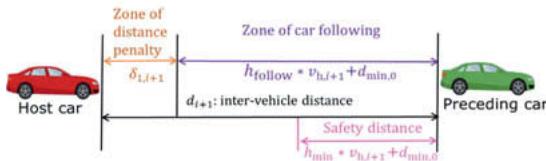


Fig. 6: Scheme of the inter-vehicle distance control

### 3.3 Control scheme with multiple approximation functions

In order to use the multiple power approximation functions for estimating the control cost within the control horizon more accurately, the following steps are taken:

Step I. Offline calculation: the minimization arguments  $p_{**}$  of (5) are calculated first without the weighting factor  $W_b$  and denoted by  $p_{**\_in}$ . The power approximation function (5c) with using  $p_{**\_in}$  is named  $f_{in}$ . Then, with  $W_b$  being included, (5) is repeatedly solved for each biased point. As there are 20 biased points as shown in Fig. 4, 20 sets of  $p_{**}$ , which corresponds to each biased point, are calculated separately. As this step is executed offline, the results of  $p_{**\_in}$  and 20 sets of  $p_{**}$  are stored after the calculation.

- Step II. Online calculation with the single approximation function: at each control step  $i$ , the optimization problem (6) is solved first with using  $f_{\text{in}}$ . After the first optimization, the initial optimal sequences of the control variable  $\{F_{t,i,\text{in}}, \dots, F_{t,i+H-1,\text{in}}\}$  and state variable  $\{v_{h,i,\text{in}}, \dots, v_{h,i+H-1,\text{in}}\}$  are obtained, as well as the optimal value of (6a) within the horizon  $H$ , which is named  $V_{\text{in}}$ .
- Step III. Selection of the multiple approximation functions: within the control horizon  $H$ , at the step  $i$ , the biased point that is the nearest to the point  $[F_{t,i,\text{initial}}, v_{h,i,\text{initial}}]^T$  is selected. The specific  $p_{**}$  corresponding to this biased point is used to build one biased approximation function which is named  $f_{\text{bias}_1}$ . Similarly, the next  $H - 1$  biased functions are created through selecting  $H - 1$  sets of  $p_{**}$ , depending on the points  $[F_{t,i+1,\text{in}}, v_{h,i+1,\text{in}}]^T, \dots, [F_{t,i+H-1,\text{in}}, v_{h,i+H-1,\text{in}}]^T$ , which are calculated at Step II.
- Step IV. Online calculation with multiple approximation functions: after Step III,  $H$  biased approximation functions are created, namely,  $f_{\text{bias}_1}, \dots, f_{\text{bias}_H}$ . Then, the single power approximation function  $f$  in (6a) is replaced by

$$\begin{aligned} \min_{F_{t,i}, \dots, F_{t,i+H-1}, F_{b,i}, \dots, F_{b,i+H-1}} & (f_{\text{bias}_1}(F_{t,i}, v_{h,i}) + \dots + f_{\text{bias}_H}(F_{t,i+H-1}, v_{h,i+H-1}) \\ & + w_1 \delta_1^2 + w_2 \delta_2^2 + w_3 (F_{b,i}^2 + \dots + F_{b,i+H-1}^2)) \end{aligned} \quad (7)$$

With all previous constraints in (6) being kept the same, additional  $H$  constraints are added to the new optimization problem (7), i.e.,

$$\begin{cases} |F_{t,i} - F_{t,\text{bias}_1}| \leq \Delta_{\text{solutions}} \\ \vdots \\ |F_{t,i+H-1} - F_{t,\text{bias}_H}| \leq \Delta_{\text{solutions}} \end{cases} \quad (8)$$

In (8),  $\Delta_{\text{solutions}}$  is a constant. The motivation of adding (8) is to search the new optimal solution within a bounded area, which is not far from the biased point, as biased power approximation gives the better approximation only around the biased point. After the optimisation problem (7) is solved with both previous and newly added constraints, the optimal value of the cost function is named  $V_{\text{bias}}$ . If  $V_{\text{bias}}$  is smaller than  $V_{\text{in}}$ , the new optimization solution at Step IV will replace the old solution at Step II. Otherwise, the old solution will be taken.

## 4 Simulation Results of EACC

### 4.1 Design of the test cycle

In order to evaluate the performance of EACC and investigate the potential of fuel reduction by EACC in real daily driving situations, a test cycle of 87.3 km is created with the recorded

driving data of one driver. The test cycle meets the European real driving emissions (RDE) test regulations [10], which are given in Table 1.

Table 1: Specification of European real driving emissions (RDE) test regulation

Specification	Driving area	Requirement of the RDE Test	Test cycle
Trip composition	City area	29% – 44% of the total trip	33.3%
	Rural area		32.1%
	Highway		34.6%
Trip duration		90 – 120 min	99.1 min
Average Speed	City area	15 – 40 km/h	29.2 km/h
Minimum Distance	City area	> 16 km	29.1 km
	Rural area		28.0 km
	Highway		30.2 km
Maximum Speed	Highway	145 km/h	137.1 km/h
Driving time	Highway	At least 5 min with speed > 100 km/h	11.5 min
Stop time	City area	6% – 30% of the time duration	15.8%

Fig. 7 demonstrates the speed profile of the test cycle, which consist of the driving situations in both city and rural area, as well as on the highway.

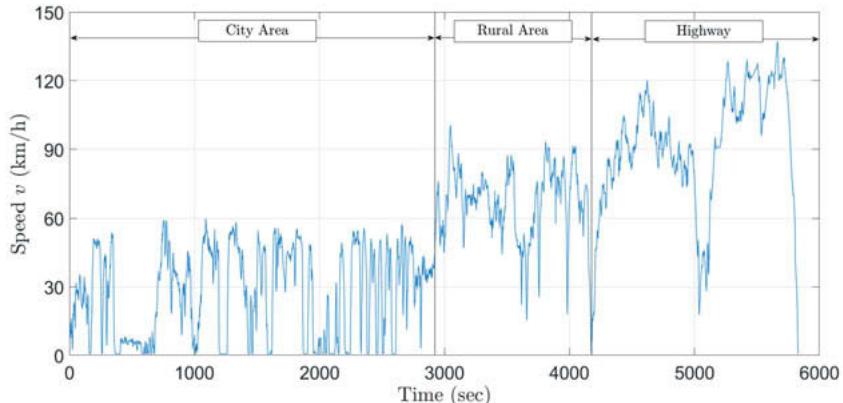


Fig. 7: Speed profile of the test cycle

## 4.2 Results of simulation test

The speed profile of the test cycle is used in simulation as the speed trajectory of a virtual preceding car. The host car, which is controlled by MPC-based EACC, has a priori information about the speed of the preceding car in next seconds and use this information to optimally plan its own speed. In order to provide insights into the vehicles' behaviours in different situations, three sections are taken out from the test cycle of 87.3 km.

The first section shown in Fig. 8 illustrates how the controlled host car behaves differently from its preceding car during the driving in a city. The preceding car decelerates strongly from around 50 km/h to a standstill when it approaches the red traffic light. It is noticeable that the preceding car accelerates sometimes before the strong deceleration, which results in an increase of fuel consumption. As a comparison, the host car decelerates softer when it knows that a deceleration is needed ahead. The non-economical driving pattern, i.e., making acceleration before the strong deceleration, is mitigated by MPC-based EACC. In Fig. 8, it is observable that the host car's speed profile is smoother than its preceding car, not only at the traffic light but also in other situations. Due to this economical and smooth driving behaviour, the host car consumes less fuel than its preceding car, while it still follows the preceding car with keeping a reasonable inter-vehicle distance.

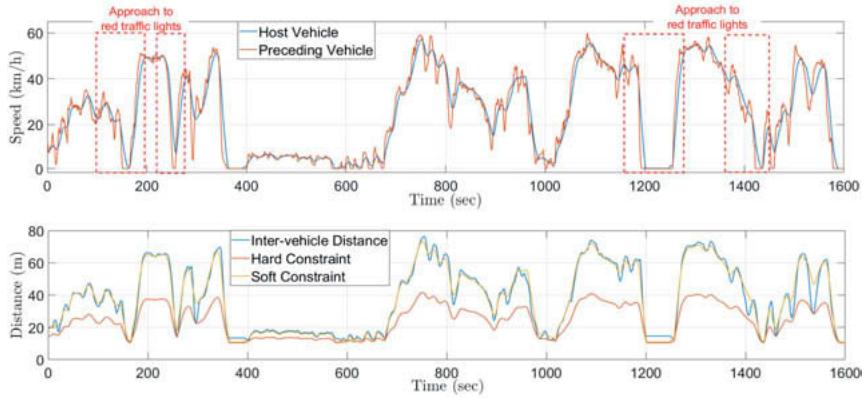


Fig. 8: One section of the simulation in the city area

The second section shown in Fig. 9 depicts the performance of EACC when driving in the rural area. It can be seen that the coasting function is activated by the host car on downhill slopes, which is beneficial to fuel reduction. In contrast to the host car, the preceding car applies more frequent and bigger braking force on slopes, which causes the dissipation of the kinetic energy.

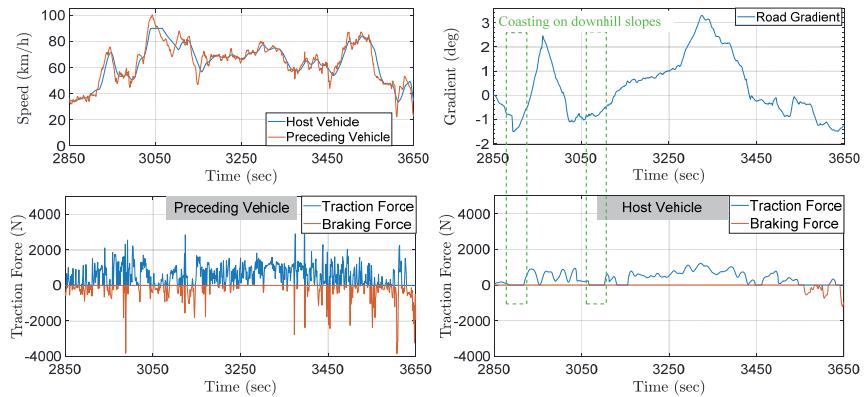


Fig. 9: One section of the simulation in the rural area

The third section shown in Fig. 10 demonstrates the vehicles' behaviour on highways. Compared to the driving in the city area, the speed variation of the preceding car becomes

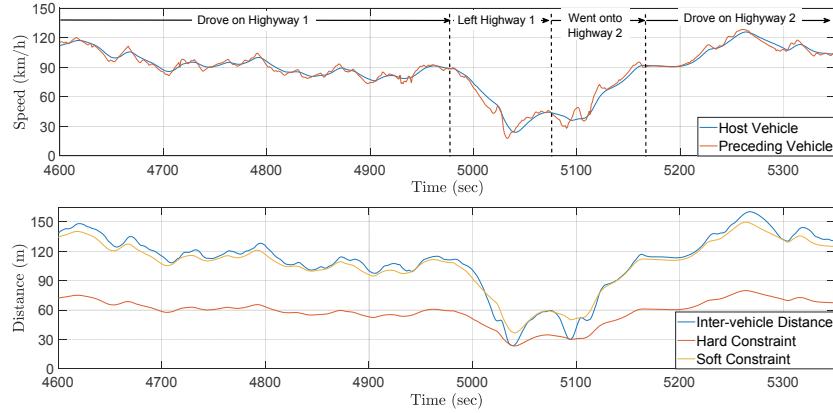


Fig. 10: One section of the simulation on highways

smaller on the highway. The big speed fluctuation between the 5000 sec and 6000 sec happens because the preceding car leaves one highway and goes onto another highway. This

speed fluctuation has also been smoothed by the host car, through which the energy efficiency of the host car is higher than its preceding car. The simulation test on highways also provides an evidence that the host car can follow the preceding car well at high driving speed.

Through analysing the energy consumption of both preceding car and host car in the complete RDE test cycle, Fig. 11 presents the fuel saving of the host car comes from which driving situations. As the preceding car has a more frequent and bigger change in the vehicle speed during the driving in a city, the biggest portion of the fuel reduction is from the city area. The eco-driving at the traffic light shows its importance as it contributes to around two third of the fuel reduction during the period of city driving.

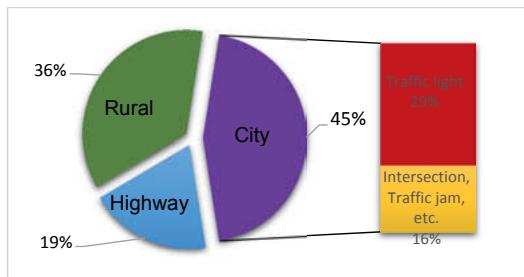


Fig. 11: Ratio of fuel reduction in different situations to the total fuel reduction in the test cycle

#### 4.3 Influence of available future information on EACC

It needs to be pointed out that the behavior of the host car shown in Subsection 4.2 is obtained with utilizing accurate information about the preceding car's speed in eight seconds ahead. However, for a practical application, it can be difficult to accurately predict the speed of the preceding car, especially for a long horizon [11]. Therefore, it is investigated in this work how EACC performs with different available information about the preceding car.

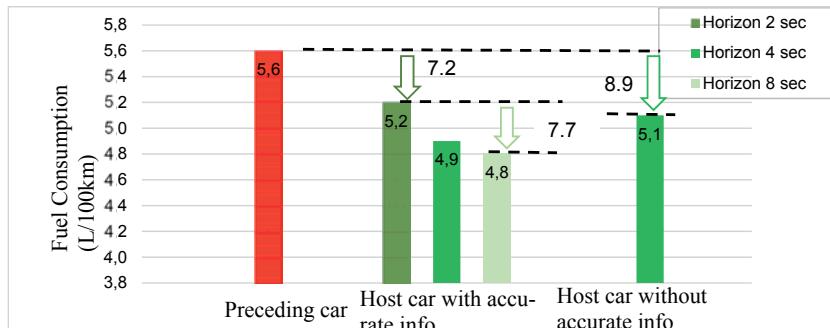


Fig. 12: Performance of EACC with different information about the preceding car's future speed

Fig. 12 summarizes the investigation result in simulation. It shows that 7.2% fuel reduction is obtained when the preceding car's speed in two seconds is precisely known in advance, while the potential of further fuel reduction by another 7.7% can be expected when the preceding car's future speed in eight seconds is available. When the accurate future speed of the preceding car is unknown, it is assumed that the preceding car's speed keeps the same with its speed at the current step within the control horizon. Although this assumption is not accurate, it is updated after one sample time, as MPC calculates the new solution at control step  $i$ . Due to this good feature of MPC, EACC reduces the fuel consumption of the host car by 8.9%, even without having the accurate information of its preceding car's future speed.

## 5 Conclusion and Future Work

In this work, the method of more accurate power approximation with multiple convex functions is proposed, with which MPC-based EACC optimizes the power consumption for the host car. The host vehicle's behaviour controlled by MPC is analysed in different driving situations through simulation, which illustrates how the host car benefits from EACC, not only in terms of the fuel consumption but also the driving's smoothness and the car following ability. The effect of available information about the preceding car's future speed on MPC-based EACC is also shown in this work.

As future work, the MPC-based EACC will be developed further from the continuous QP problem to hybrid control so that the discrete control variables (e.g., engine On/Off switch) can be taken into account. To enlarge the benefit of fuel reduction in application, not only the controller

but also the speed prediction models will be researched in some critical driving situations (e.g., at the traffic light).

## 6 References

- [1] L. Xiao and F. Gao, "A comprehensive review of the development of adaptive cruise control systems," *Vehicle System Dynamics*, vol. 48, pp. 1167-1192, 2010.
- [2] M. Sivak and B. Schoettle, "Eco-driving: Strategic, tactical, and operational decisions of the driver that influence vehicle fuel economy," *Transport Policy*, vol. 22, pp. 96-99, 2012.
- [3] M. Kyriakidis, C. v. d. Weijer, B. v. Arem and R. Happee, "The deployment of Advanced Driver Assistance Systems in Europe," in *22nd ITS World Congress*, 2015.
- [4] A. Weißmann, D. Görges and X. Lin, "Energy-Optimal adaptive cruise control based on model predictive control," *Control Engineering Practice*, vol. 72, pp. 125-137, 2018.
- [5] M. S. Kamal, M. Mukai, J. Murata and T. Kawabe, "Model Predictive Control of Vehicles on Urban Roads for Improved Fuel Economy," *IEEE Transactions on Control Systems Technology*, vol. 21, no. 3, pp. 831-841, 2013.
- [6] Y. Jia, T. Saito and D. Görges, "Energy-optimal adaptive cruise control in time domain based on model predictive control," *IFAC-PapersOnLine*, vol. 51, no. 31, pp. 846-853, 2018.
- [7] T. Schwickart, H. Voos, J.-R. Hadji-Minaglou and M. Darouach, "A novel model-predictive cruise controller for electric vehicles and energy efficient driving," in *IEEE International Conference on Advanced Intelligent Mechatronics*, 2014.
- [8] T. Stanger and L. d. Re, "A model predictive Cooperative Adaptive Cruise Control approach," in *American Control Conference (AAC)*, 2013.
- [9] U. Kiencke and L. Nielsen, *Automotive control systems: for engine, driveline, and vehicle*, Springer, 2000.
- [10] "European Commission (2016). Commission regulation (EU) no. 2016/427.".
- [11] A. Rezaei and J. B. Burl, "Prediction of Vehicle Velocity for Model Predictive Control," *IFAC-PapersOnLine*, vol. 48, pp. 257-262, 2015.

# Proof-of-Concept einer komplexen Co-Simulationsumgebung für einen Fahrsimulator zur Untersuchung von Car2X-Kommunikations-Szenarien

M.Sc. **Sven Henning**, M.Sc. **Dominik S. Buse**, B.Sc. **Mario Franke**,  
Prof. Dr.-Ing. habil. **Ansgar Trächtler**, Dr.-Ing. **Sandra Gausemeier**,  
Prof. Dr.-Ing. habil. **Falko Dressler**,  
Heinz Nixdorf Institut, Universität Paderborn

## 1. Zusammenfassung

Für die voranschreitenden Entwicklungen moderner Fahrerassistenzsysteme (Advanced Driving Assistance Systems, kurz: ADAS) werden heutzutage verschiedenste Simulationsumgebungen eingesetzt. So existieren Fahrsimulatoren unterschiedlichster Komplexitätsgrade für virtuelle Testfahrten, Verkehrssimulationen mit Fremdverkehr zur Untersuchung umfangreicher Straßennetze und Simulationsumgebungen für die Kommunikation zwischen Fahrzeugen (Car2X-Kommunikation). Jede dieser Simulationsumgebung erfüllt für sich einen speziellen Zweck, jedoch existieren bisher keine Lösungen, alle genannten Funktionen in einer Gesamtsimulation zu vereinen. Dieser Beitrag zeigt daher einen Proof-of-Concept einer Co-Simulationsumgebung, welche die genannten Funktionen vereint. Die vorgestellte Simulationsumgebung ermöglicht einem menschlichen Fahrer ein virtuelles Fahrerlebnis in einem Fahrsimulator mit intelligentem Fremdverkehr sowie Car2X-Kommunikation. Es werden Herausforderungen bei der Synchronisierung der Einzelsimulationen und bei der Einhaltung von Echtzeitbedingungen an das Gesamtsystem aufgezeigt sowie eine Bewertung der Leistungsfähigkeit vorgenommen. Ein einfaches Testscenario für ein vernetztes ADAS schließt den Beitrag ab.

## 2. Abstract

For the progressive development of modern Advanced Driving Assistance Systems (ADAS), a wide variety of simulation environments are used nowadays. Driving simulators of various degrees of complexity exist for virtual test drives, traffic simulations involving external traffic for the investigation of complex road networks as well as simulation environments for communication between vehicles (Car2X communication). Each of these simulation environments serves a specific purpose, but so far there are no solutions to combine all mentioned functions in one overall simulation. This article therefore shows a proof-of-concept of a co-simulation environment that combines the above mentioned functions. The presented simulation environment provides a human driver to have a virtual driving experience in a driving simulator with intelligent external traffic and Car2X communication. Challenges for the synchronization of the individual simulations and the fulfillment of real-time conditions to the

overall system are shown and an evaluation of the performance is carried out. A simple test scenario for a networked ADAS completes the contribution.

### 3. Einleitung und Motivation

Moderne ADAS steigern Sicherheit, Effizienz und Komfort im Straßenverkehr. Klassischerweise vom Fahrer übernommene Fahrfunktionen können durch den Einsatz von Sensoren, Aktoren und entsprechender Logik durch das Fahrzeug unterstützt oder übernommen werden. In [10] und [11] geben die Autoren eine Übersicht über die Vielzahl klassischer und moderner ADAS, die die Sicherheit oder den Komfort steigern. Die Verwendung von Fahrsimulatoren unterschiedlichster Ausprägung zum Test von ADAS während der Entwicklung stellt bereits heute in vielen Fällen den Stand der Technik dar. Gerade in Hinsicht auf moderne Funktionen für (teil-)autonom fahrende Fahrzeuge, deren Entwicklung neue Herausforderungen mit sich bringt, weist die modellbasierte und simulationsgestützte Entwicklung Vorteile gegenüber aufwendigen und in der Regel kostenintensiven Prototypentests auf. Beispielsweise werden am Heinz Nixdorf Institut der Universität Paderborn mehrere Fahrsimulatoren für verschiedene Anwendungszwecke betrieben; von einfachen Bildschirmen mit Lenkrad, Gas- und Bremspedalen bis hin zu einem Fahrsimulator mit einem 5-Freiheitsgrade-Bewegungssystem, einem Fahrzeug-Chassis sowie einer Rundprojektion (vgl. Abbildung 1).



Abbildung 1: Fahrsimulatoren unterschiedlicher Komplexität am Heinz Nixdorf Institut

Für den Fahrsimulator, in Abbildung 1 links dargestellt, wurde in [8] und [9] exemplarisch eine rekonfigurierbare Simulationsumgebung vorgestellt, die aus mehreren Komponenten besteht. Die Komponenten umfassen eine Bewegungsplattform mit realem Fahrzeugchassis, in dem ein Mensch die Möglichkeit hat, haptisch in einem Fahrsimulationsszenario zu interagieren und die wirkenden Beschleunigungen und Drehraten einer Fahrt zu erleben (vestibuläre Reize). Hierzu werden sog. Motion-Cueing-Algorithmen mit dem Ziel eingesetzt, die

Beschleunigungen und Drehraten unter Berücksichtigung der Beschränkungen des Fahrsimulators möglichst realitätsnah wiederzugeben. In [7] wurde zur Umsetzung eines solchen Algorithmus ein vielversprechender Ansatz präsentiert, der auf einer echtzeitfähigen modellprädiktiven Regelung basiert und eine sehr hohe Regelgüte erzielt. Außerdem wird ein echtzeitfähiges Fahrdynamikmodell für das Ego-Fahrzeug<sup>1</sup> eingesetzt, welches zum einen die simulierten Beschleunigungsgrößen und Drehraten für den zuvor erwähnten Motion-Cueing-Algorithmus berechnet und zum anderen die Position und Lage des Ego-Fahrzeugs bereitstellt, die für eine 3D-Darstellung notwendig sind. Die Rundprojektion stellt dem Fahrer mit Hilfe einer selbstentwickelten 3D-Visualisierung (Unity3D<sup>2</sup>) automatisch erzeugte 3D-Szenen dar während eine rudimentäre Fremdverkehrssimulation weitere Fahrzeuge in der Szene simuliert. Mit Systemen wie diesem können Tests früher im Entwicklungszyklus durchgeführt und durch kontrollierte Testbedingungen vergleichbar reproduziert werden, was Entwicklungskosten im Vergleich zu klassischen Prototypentests senken kann. In [25] wurde mit der vorgestellten Simulationsumgebung beispielsweise erfolgreich ein lichtbasiertes Fahrerassistenzsystem entwickelt und simulativ erprobt, bevor die abschließende Entwicklungsphase mit realen Tests begonnen wurde. Jedoch ist die Einsatzmöglichkeit des Fahrsimulators beschränkt, da bisher kein interaktiver und intelligenter Fremdverkehr existiert und nicht alle notwendigen Technologien für zukünftige ADAS integriert sind. Ziel ist es daher, diese für zukünftige Untersuchungen am Fahrsimulator nutzbar zu machen.

Zu solchen Technologien zukünftiger ADAS zählen beispielsweise eine Drahtloskommunikation zwischen Fahrzeugen sowie der Verkehrsinfrastruktur (Car2X-Kommunikation). Damit ergeben sich Quellen für Umgebungsdaten jenseits der Reichweite der fahrzeugeigenen Sensoren sowie die Möglichkeit kooperativer Fahrmanöver. Die Vernetzung der Systeme erschwert durch die erhöhte Komplexität jedoch auch die Sicherstellung ihrer Funktion. Statt den Systemen von nur einem Fahrzeug müssen zukünftig Netzwerke von Fahrzeugen und ihre Interaktionen untereinander untersucht werden.

Die Kommunikation ist als Schlüsseltechnologie für vernetzte ADAS aufzufassen, die den zukünftigen Verkehr mithilfe von autonomen Fahrfunktionen sicherer und effizienter gestaltet können. In [12] wird das Konzept eines selbstorganisierenden Verkehrsinformationssystems erläutert, welches auf dezentraler Car2X-Kommunikation basiert und die Möglichkeit eröffnet, dass die Fahrzeuge selbständig den aktuellen Verkehrszustand erfassen und diese Information an andere Fahrzeuge weitergeben. Solche Informationen bilden die Grundlage für vernetzte Verkehrsmanagementansätze. In [6] wurde als eines von vielen Beispielen in der Literatur ein Konzept für ein hierarchisches Verkehrsmanagement vorgestellt, das basierend auf der Annahme, dass der Verkehr vollständig autonom abgehandelt wird und eine Car2X-Kommunikation existiert, eine Balancierung der Verkehrswegeauslastung ermöglicht und

<sup>1</sup> Als Ego-Fahrzeug wird das eigene Fahrzeug aus Sicht des Fahrers genannt (i.d.R. ist dies ein Mensch)

<sup>2</sup> Unity3D ist eine Laufzeit- und Entwicklungsumgebung für Spiele

somit Risiken von Stauungen sowie die mittleren Reisezeiten der Fahrzeuge reduziert. In dem Beitrag wurde die Kommunikation zwischen den Fahrzeugen jedoch vereinfacht als ideal und frei von Latenzen und Störungen angenommen und spiegelt damit die in der Realität vorhanden Gegebenheiten nicht korrekt wider. Eine ganzheitliche Untersuchung von vernetzten ADAS muss daher auch die Car2X-Kommunikation berücksichtigen. Mit speziellen Simulationsumgebungen zur Untersuchung von Fahrzeugnetzwerken können Effekte der Informationsübertragung bereits simuliert und bei der Umsetzung von ADAS einbezogen werden. Ebenso bleibt der menschliche Fahrer ein wichtiger Einflussfaktor – sowohl als Nutzer des ADAS als auch als Fahrer anderer Fahrzeuge, denn der Übergang zum autonomen Fahren wird ein fließender Übergang mit teil-autonomen Mischverkehr (autonom / nicht autonom) sein. Die Berücksichtigung des menschlichen Verhaltens in Form von zusätzlichem intelligentem Fremdverkehr in der Fahrsimulation ist ebenfalls Stand der Technik.

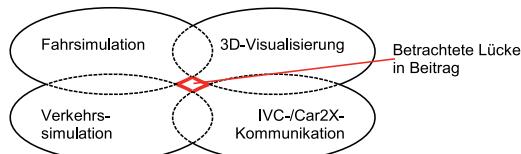


Abbildung 2: Teilgebiete der Fahrsimulation sowie deren Überlappungen, in Rot: In diesem Beitrag geschlossene Lücke

Für Teilgebiete sind also bereits Lösungen vorhanden. Jedoch existiert bisher keine Möglichkeit, eine komplexe Fahrsimulation mit intelligentem Fremdverkehr, integrierter Car2X-Kommunikation sowie dem menschlichen Fahrer mit seinem schwer vorhersagbaren Verhalten in einer einzigen Gesamtsimulation zu untersuchen oder für die Evaluierung von ADAS nutzbar zu machen. Diese Lücke zeigt sich an den Überlappungen dieser Teilgebiete (siehe auch Abbildung 2). Dieser Beitrag erläutert einen Proof-of-Concept für eine Co-Simulationsumgebung, die den Funktionsumfang mehrerer Simulationsumgebungen bzw. -konzepte vereint. Hierbei werden besondere, in diesem Kontext auftretende Problemstellungen aufgezeigt und mögliche Lösungen gegeben (bspw. Kopplung mehrerer Simulationen).

#### 4. Stand der Technik

Wie bereits in Abbildung 2 zu erkennen ist, besteht eine umfassende Fahrsimulation oft aus mehreren Einzelkomponenten, die zu einer Gesamtsimulation kombiniert werden. In der Literatur sind einige Kombinationen aus Einzelsimulationen bereits diskutiert worden und sollen kurz vorgestellt und verglichen werden.

In [2] stellen die Autoren die bidirektional gekoppelte Simulationsumgebung Veins vor, die auf der diskreten ereignisorientierten Simulation OMNeT++ (**O**bjective **M**odular **N**etwork **T**estbed in **C++**) [15] und der Verkehrssimulation SUMO (**S**imulation of **U**rban **M**Obility) [11] basiert.

Veins implementiert mithilfe von OMNeT++ eine komplexe Car2X-Kommunikation, die eine Simulation selbiger über mehrere Abstraktionsschichten hinweg ermöglicht. Dabei wird die bereitgestellte Netzwerkschnittstelle TraCI [14] zum synchronisierten Datenaustausch verwendet (vgl. Abbildung 3). Veins wird zur simulativen Untersuchung von sog. VANETs (Vehicular ad-hoc networks) eingesetzt.

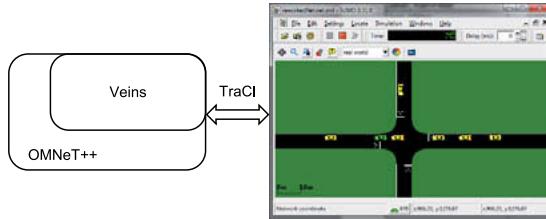


Abbildung 3: Kombination der Car2X-Kommunikationssimulation Veins (links) mit der Verkehrssimulation SUMO (rechts)

Veins ist in der Lage, physikalische Effekte der Kommunikation zu simulieren. Dazu gehören bspw. die Wellenausbreitung, Interferenzen, Antennengeometrien, Abschattungen durch Objekte oder die Leistungsaufnahme von Sendern und Empfängern für alle in der Simulation vorkommenden Fahrzeuge [2]. Darüber hinaus werden Protokolle und Standards auf MAC-Ebene (Media Access Control) berücksichtigt, die für die Kommunikation notwendig sind sowie die Möglichkeit gegeben, darauf aufsetzend Kommunikationsanwendungen zu implementieren. Diese umfassen u.a. IEEE 802.11p, Wi-Fi und DSRC (Dedicated Short-Range Communications), welche in [1] detaillierter diskutiert werden. Ein Fahrsimulator, ein detailliertes Fahrdynamikmodell sowie eine interaktive 3D-Umgebung sind jedoch nicht enthalten. In [3] stellen die Autoren ein sog. Ego-Vehicle-Interface (EVI) vor, welches ein echtzeitbasiertes Hardware-in-the-Loop-System (HiL) mit Veins synchronisieren kann und stellt somit die Grundlage zur Einbringung eines komplexen Fahrdynamikmodells, das z.B. auf einer echtzeitfähigen Hardware berechnet wird. Somit konnten die Autoren in [3] die angesprochene Lücke zum Teil schließen. Der EVI-Ansatz wird in [4] und [5] weiter ausgearbeitet, welche Grundlagen für diesen Beitrag aufweisen. Die Autoren in [16] stellen ein gekoppeltes System aus einer 3D-Visualisierung und einer eigenen Verkehrssimulation vor. In [17] wird ein System präsentiert, welches, wie auch in [8] gezeigt, ein komplexes Fahrdynamikmodell einsetzt und ebenfalls eine 3D-Visualisierung umfasst, wobei jedoch Monitore und keine Rundprojektion als Ausgabegeräte eingesetzt wurden. Eine weitere Veröffentlichung [18] zeigt die Kombination eines realen Fahrzeugs und der Verkehrssimulation SUMO, bei der der Informationsaustausch durch Smartphones umgesetzt wurde. Die Kombination aus einer 3D-Visualisierung, einer Verkehrssimulation, einer Car2X-Kommunikationssimulation und einer Fahrdynamiksimulation stellen die Autoren in [19] vor. Jedoch wurden alle Komponenten selbst entwickelt und aus Echtzeitgründen in Unity3D

implementiert, sodass der Funktionsumfang beschränkt ist. In [20] wird das System „Distributed Virtual Environment“ (kurz DiVE) vorgestellt. Die in einer Server/Client-Struktur angelegte Simulationsumgebung ermöglicht es mehreren Menschen in einem gemeinsamen Szenario zu interagieren. Zusätzlich wird eine eigene Car2X-Kommunikationssimulation basierend auf OMNeT++ eingesetzt. Jedoch wird für das Ego-Fahrzeug auf ein in Unity3D integriertes und stark vereinfachtes Fahrdynamikmodell zurückgegriffen. An der Universität Buffalo wurde ein umfangreiches Gesamtsystem entwickelt, das aus dem proprietären Verkehrssimulator Paramics, dem Netzwerksimulator NS2 und einem Fahrsimulator mit Bewegungsplattform besteht (also auch ein entsprechend umfangreiches Fahrdynamikmodell beinhaltet) und damit alle notwendigen Funktionen erfüllt, jedoch durch die proprietären Softwarebestandteile wenig flexibel ist.

Zusammenfassend kann festgestellt werden, dass es durchaus Ansätze gibt, verschiedene Simulationsumgebung zu kombinieren, um eine realistischere Fahrsimulation zu ermöglichen. Allerdings ist ebenfalls ersichtlich, dass eine volumnfassende Kombination von Verkehrssimulation und Car2X-Kommunikationssimulation sowie einem detaillierten Fahrdynamikmodell und einer 3D-Visualisierung nicht existiert. In Tabelle 1 ist eine Übersicht der verschiedenen vorgestellten Ansätze zu sehen.

*Tabelle 1: Vergleich verschiedener kombinierter Fahrsimulationsumgebungen*

Quelle	3D-Visualisierung	Verkehrs-simulation	Car2X-Kommunikations-simulation	Fahrdynamik-simulation
[2]	Nein	SUMO	OMNeT++/Veins	Nein
[3]	Erweiterbar	SUMO	OMNeT++/Veins	Erweiterbar
[8]	Unity3D	Nein	Nein	MATLAB/Simulink
[16]	Unity3D	Eigenes Modell	Nein	Nein
[17]	Ja	Nein	Nein	Eigenes Modell
[18]	Echtes Fahrzeug	SUMO	Nein	Echtes Fahrzeug
[19]	Unity3D	Modell in Unity3D	Modell in Unity3D	Modell in Unity3D
[20]	Unity3D	Eigenes Modell	Basierend auf OMNeT++	Modell in Unity3D
[21]	Ja	Paramics	NS2	Eigene Plattform

## 5. Konzept und Implementierung

Im Folgenden wird die Gesamt simulationsumgebung vorgestellt, welche mit der erweiterten Synchronisationsschnittstelle EVI (Ego Vehicle Interface) die vier einzelnen Komponenten miteinander verkoppelt, aus denen das System besteht. Wie in Abbildung 4 links dargestellt, besteht das Gesamtsystem aus einer Kommunikationssimulation, einer Verkehrssimulation, einer Fahrdynamiksimulation für das Ego-Fahrzeug und einer 3D-Visualisierung mit Ausgabe. Die Verkehrssimulation übernimmt die Aufgabe, alle Fremdverkehrs fahrzeuge sowie deren Verhalten für einen Straßennetzausschnitt zu simulieren. In diesem Beitrag wird die Simulationsumgebung SUMO [13] eingesetzt.

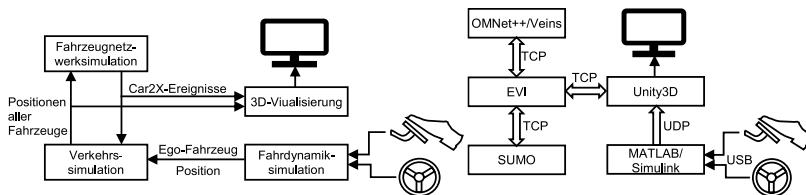


Abbildung 4: Links: Informationsfluss zwischen den Einzelsimulationen, Rechts: Umsetzung der Kombination durch die Implementierung von EVI

SUMO besitzt zu jedem Zeitpunkt die Informationen über die Position und Lage aller Fahrzeuge sowie über das Straßennetz (z.B. Straßengeometrien, Hindernisse wie Gebäude etc.) und kann diese den anderen Simulationsumgebungen zur Verfügung stellen. Zusätzlich können extern gesteuerte Fahrzeuge (Ego-Fahrzeuge) über Positionsinformationen eingebunden werden, auf die der Fremdverkehr entsprechend reagiert. Das in SUMO verwendete Straßennetz ist als globales Modell für alle Simulationsumgebungen zu betrachten und kann synthetischer Natur sein oder aus OpenStreetMap<sup>3</sup>-Kartenmaterial erzeugt werden. Als Kommunikationssimulation wird Veins/OMNeT++ eingesetzt, das wie zuvor erläutert eine sehr detaillierte Abbildung der Kommunikation zwischen Fahrzeugen erlaubt und zudem für die Verwendung mit SUMO ausgelegt ist (vgl. Abbildung 3). Die Car2X-Ereignisse, die in Veins/OMNeT++ auftreten (z.B. ADAS-Nachrichten), werden an SUMO zur Benachrichtigung der simulierten Fahrzeuge sowie an die 3D-Visualisierung für eine etwaige optische Benachrichtigung des menschlichen Fahrers weitergeleitet. Da der Beitrag eine Machbarkeit darstellt, wurde nicht der in Abbildung 1 links dargestellte Fahrtsimulator als Plattform gewählt, sondern aus Gründen der Vereinfachung ein weniger komplexes System eingesetzt, welches im Folgenden erläutert wird. Die Erkenntnisse der Untersuchung sind jedoch übertragbar. Die 3D-Visualisierung besteht aus einer Unity3D-Anwendung, die automatisiert 3D-Szenarien auf Grundlage eines SUMO-Straßenetzmodells erzeugen kann und die Bewegungen aller Verkehrsteilnehmer inkl. des Ego-Fahrzeugs darstellt. Die Ausgabe der 3D-Visualisierung erfolgt in diesem Beitrag durch einfache Monitore oder durch eine Virtual-Reality-Brille. Als Fahrdynamikmodell wird ein komplexes Vollfahrzeugmodell verwendet, das hauptsächlich ein Zweispurmodell mit vier Freiheitsgraden (FHG) für die Horizontaldynamik (zwei translatorische FHG in der Ebene, der Gierwinkel und Schwimmwinkel) umfasst und mit einem Vertikaldynamikmodell mit elf FHG verkoppelt ist (Huben, Nicken, Wanken, vier Verdrehwinkel der Räder und vier vertikale translatorische FHG der Räder). Zusätzlich enthält das Vollfahrzeugmodell zur Abbildung der Reifenkräfte Reifenmodelle nach Pacejka sowie ein einfaches Antriebsstrangmodell, das aus Motor, Getriebe und Differential besteht. Das

<sup>3</sup> OpenStreetMap ist ein freies Projekt, das frei nutzbare Geodaten sammelt, strukturiert und für die Nutzung durch die Allgemeinheit in einer Datenbank bereitstellt

Fahrdynamikmodell wurde in Matlab/Simulink implementiert und wird als Echtzeitsimulation mit einer Schrittweite von einer Millisekunde auf einem Windows-PC ausgeführt. Alternativ dazu ist ebenso eine Ausführung auf einer Echtzeithardware (vgl. [3]) möglich, um harte Echtzeit zu garantieren. Das Fahrdynamikmodell besitzt drei Eingänge, die von einem menschlichen Fahrer beeinflusst werden können: Den Lenkradwinkel, die Gaspedalstellung und die Bremspedalstellung (das Getriebe des Fahrdynamikmodells ist als Automatik ausgelegt). Diese Eingangsgrößen werden im einfachsten Fall über ein per USB an den PC angeschlossenes Lenkrad mit Pedalen erfasst. Die Ausgänge sind die Position und die Orientierung des Ego-Fahrzeugs, die an SUMO weitergeleitet werden.

Abbildung 4 rechts zeigt, an welcher Stelle nun EVI ansetzt wird und wie die notwendigen Informationen ausgetauscht werden. EVI nimmt hier die Rolle eines zwischengeschalteten Brokers ein, der für die Einzelsimulationen alle notwendigen Informationen erhält und sie für die Einzelsimulationen im entsprechenden Format weiterleitet. Hierbei wählt EVI die lokal zu berücksichtigen Verkehrsumgebung selbst aus. Diese Struktur ist möglich, da alle Einzelsimulationen eine Netzwerkschnittstelle per TCP/UDP bereitstellen. Als Besonderheit wird hier das von Matlab/Simulink berechnete Fahrdynamikmodell nicht direkt an SUMO, sondern an Unity3D gekoppelt, da an dieser Stelle reine Daten ohne Einsatz eines Protokolls übertragen werden. Die Implementierung von EVI nutzt ein Publish/Subscribe-Entwurfsmuster, welches durch die Nachrichtenaustausch-Bibliothek ZeroMQ [22] bereitgestellt wird.

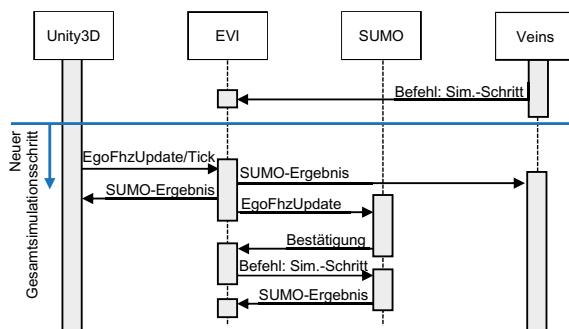


Abbildung 5: Sequenzdiagramm eines synchronisierten Simulationsschritts

Zur Strukturierung der Daten wird das zugrundeliegende TraCI-Protokoll [14] verwendet, welches die meisten notwendigen Funktionen umfasst und von SUMO und Veins bereits unterstützt wird. Jedoch sind zusätzlich Datenstrukturen notwendig, um die 3D-Visualisierung über Car2X-Ereignisse zu benachrichtigen, die durch TraCI nicht berücksichtigt werden. Da die Erweiterung des TraCI-Protokolls sehr aufwendig ist, wurde in EVI eine Datenserialisierung

mittels Google Protocol Buffers<sup>4</sup> implementiert, die TraCI-Datenpakete einbettet und diese zwischen SUMO und Veins vermitteln kann, während zusätzlich beliebige weitere Daten anderer Struktur angehängt werden können. In Abbildung 5 ist das Sequenzdiagramm eines synchronisierten Simulationsschritts mit der verkoppelten Gesamtsimulation zu sehen. Zunächst sendet Veins aus dem vergangenen Simulationsschritt den Befehl für SUMO, den nächsten SUMO-Simulationsschritt zu berechnen. Diese Nachricht wird durch EVI entgegengenommen. EVI wartet solange, bis von Unity3D als Taktgeber das Signal für den nächsten Simulationsschritt eingeht. Der Befehl von Veins wird dann aber nicht an SUMO weitergeleitet, da EVI stets einen Simulationsschritt von SUMO im Voraus zwischenspeichert und das SUMO-Ergebnis (u.a. Fahrzeugpositionen) daher aus dem letzten Simulationsschritt direkt an VEINS zurückgeben kann (und zusätzlich an Unity3D). Dieser Ansatz wurde gewählt, da die Berechnungen in Veins sehr zeitaufwendig sind und die Verzögerung durch SUMO so gering wie möglich sein soll. Der Nachteil, dass Veins die Berechnungen daher auf einem zurückliegenden SUMO-Simulationsergebnis tätig, fällt für eine genügend kleine Simulationsschrittweite nicht negativ ins Gewicht. Zusätzlich erhält EVI von Unity3D die Position des Ego-Fahrzeugs, die an SUMO als Aktualisierung für das extern gesteuerte Fahrzeug weitergeleitet wird. Anschließend stößt EVI den nächsten Simulationsschritt in SUMO an und speichert daraufhin das Ergebnis für den nächsten Gesamtsimulationsschritt zwischen.

## 6. Untersuchung der Leistungsfähigkeit

Da SUMO und Veins ereignisorientierte Simulationen sind (d.h. es existiert keine Garantie für harte Echtzeit, da jeder Simulationsschritt unterschiedlich viel Zeit beanspruchen kann) und damit im Gegensatz zum Fahrdynamikmodell nicht echtzeitfähig Ergebnisse liefern, ist es notwendig, dass EVI diesen Umstand bei der Synchronisierung berücksichtigt. Als Echtzeitanforderung wurde für das System im Rahmen dieses Beitrags eine maximale Gesamtzeitdauer von 100 ms festgelegt, innerhalb der die Gesamtsimulation als echtzeitfähig betrachtet wird (die Immersion bleibt für den menschlichen Fahrer dann erhalten). Die Einhaltung dieser festgelegten Grenze wird im Folgenden untersucht. In [3] wurde bereits festgestellt, dass Veins im Vergleich zu SUMO (8–15 ms) einen hohen Rechenbedarf erfordert und daher neben dem Fahrdynamikmodell (1 ms pro Simulationsschritt) und der Unity3D-Visualisierung (ca. 17 ms) als kritischer Engpass für die Echtzeitanforderung zu sehen ist. Für die Untersuchung der Leistungsfähigkeit wurden zwei Versuche durchgeführt. Im ersten Versuch wurde in Veins eine Pseudo-Anwendung implementiert, die eine definierte Zeit pro Simulationsschritt wartet (statische und gleichverteilte Last). Dadurch wurde untersucht, ab welcher benötigten Rechenzeit das Gesamtsystem nicht mehr echtzeitfähig ist und die Immersion der Fahrsimulation stört.

---

<sup>4</sup> <https://developers.google.com/protocol-buffers/>



Abbildung 6: Straßenraum aus dem nördlichen Paderborn  
 Links: Ausschnitt aus OpenStreetMap mit gefahrener Strecke, Mitte: 3D-Umgebung in Unity3D,  
 Rechts: SUMO-Straßenennet

Zusätzlich wurde als zweiter Versuch eine virtuelle Rundfahrt von einem menschlichen Testfahrer in einem Szenario mit intelligentem Fremdverkehr (5 bis 25 Fremdverkehrs-Fahrzeuge) und Car2X-Kommunikation durchgeführt und zu Vergleichszwecken aufgezeichnet (s. Abbildung 6 links). In Tabelle 2 sind die für die Untersuchung verwendeten PCs aufgelistet.



Abbildung 7: Screenshot der 3D-Visualisierung

Tabelle 2: Komponenten der Simulations-PCs

Komponente	Windows 7 PC	Ubuntu 16.04 LTS PC
CPU	Intel Core i7-3770K @ 3.5 GHz	Intel Core i7-7700K @ 4.2 GHz
RAM	16 GB	16 GB
GPU	Nvidia GTX 650 Ti	Keine dedizierte Grafik
Simulationen	Matlab/Simulink R2015b, Unity3D 5.6.0f3	SUMO 0.30.0, Veins/OMNeT++ 5.1.1

Die Untersuchung hat für eine statische Last ergeben, dass Veins bis zu 95 ms (95%) der Gesamtsimulationsschrittzeit nutzen kann, ohne dass die Gesamtsimulation die Echtzeitfähigkeit verliert (vgl. Abbildung 8 links). Dasselbe Ergebnis ist zu erkennen, wenn eine gleichverteilte Last für Veins angenommen wird, die im Mittelwert jedoch ebenfalls nicht mehr als 95 ms nutzt. So ist das Gesamtsystem in einem solchen Fall in der Lage, nach mehreren Simulationsschritten mit jeweils mehr als 95 ms an Zeitbedarf wieder die Echtzeit zu erlangen und Verluste zu kompensieren. Für die Untersuchung eines einfachen Anwendungsszenarios, in dem ein menschlicher Fahrer mittels Lenkrad, Pedalen und einer Virtual-Reality-Brille eine virtuelle Testfahrt mit Fremdverkehr und einer Car2X-Kommunikation durchführt, wurde eine einfache 10Hz-Beaconing-Anwendung (Lokaler Nachrichten-Broadcast) implementiert, die Informationen zwischen den Fahrzeugen vermittelt (wie beispielweise lokal auftretende Verkehrsstörungen). Hierbei konnte festgehalten werden, dass die Anzahl der Fremdverkehrs-Fahrzeuge und die dadurch benötigte Berechnungszeit der Car2X-Kommunikation von Veins die limitierenden Faktoren der Gesamtsimulation sind, wie

in Abbildung 8 rechts dargestellt. Für die verwendete Hardware (vgl. Tabelle 2) stellte sich heraus, dass bis zu 20 Fremdverkehrsfahrzeuge echtzeitfähig mittels der Gesamt simulationsumgebung simuliert werden können.

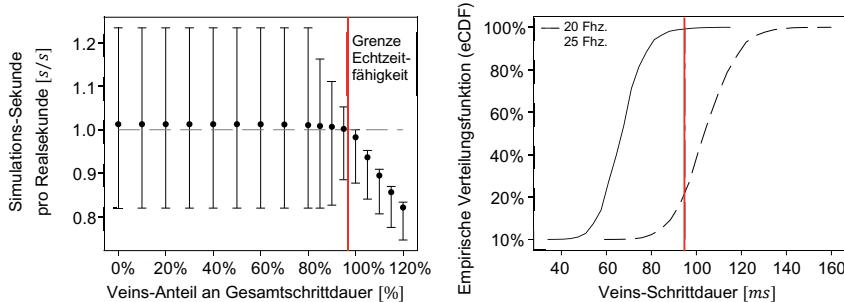


Abbildung 8: Ergebnisse der simulativen Untersuchung der Leistungsfähigkeit  
Links: Statische Last, Rechts: Virtuelle Testfahrt

## 7. Fazit

In diesem Beitrag wurde das Konzept für eine komplexe Gesamt simulationsumgebung gezeigt, die eine Kombination mehrerer Einzelsimulationsumgebungen ermöglicht. Hierzu zählen eine Simulation für intelligenten Fremdverkehr, eine detaillierte Car2X-Kommunikation für eine Beispieldienstleistung mit 10 Hz, ein komplexes Fahrdynamikmodell für das Ego-Fahrzeug und eine dynamische 3D-Visualisierung. Die Komponenten unterscheiden sich in der Art der Simulation (ereignisorientierte vs. Echtzeit-Simulation) und wurden mittels einer implementierten Schnittstelle (EVI) synchronisiert und verkoppelt. Die resultierende Gesamt simulationsumgebung konnte in Versuchen als echtzeitfähig für bis zu 20 Fremdverkehrsfahrzeuge betrachtet werden. Untersuchungen für den Einsatz mit komplexeren Fahr simulatoren stellen die nächsten möglichen Herausforderungen dar.

## Literatur:

- [1] C. Sommer, F. Dressler, „Vehicular Networking“, Cambridge University Press, Nov. 2014, DOI: 10.1017/CBO9781107110649
- [2] C. Sommer, R. German, F. Dressler, „Bidirectionally Coupled Network and Road Traffic Simulation for Improved IVC Analysis“, IEEE Transactions on Mobile Computing, vol. 10, no. 1, pp. 3–15, Jan. 2011. DOI: 10.1109/TMC.2010.133
- [3] D. S. Buse, M. Schettler, N. Kothe, P. Reinold, C. Sommer, F. Dressler, „Bridging Worlds: Integrating Hardware-in-the-Loop Testing with Large-Scale VANET Simulation“, in 14th IEEE/IFIP Conference on Wireless On demand Network Systems and Services (WONS 2018), Isola 2000, Frankreich: IEEE, Feb. 2018. DOI: 0.23919/WONS.2018.8311659
- [4] J. Heinovski, L. Stratmann, D. S. Buse, F. Klingler, M. Franke, M.-C. H. Oczko, C. Sommer, I. Scharlau, F. Dressler, „Modeling Cycling Behavior to Improve Bicyclists' Safety at Intersections – A Networking Perspective“, Proceedings of 20th IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks (WoWMoM 2019), Washington, DC, Juni 2019
- [5] D. S. Buse, C. Sommer, F. Dressler, „Integrating a Driving Simulator with City-Scale VANET Simulation for the Development of Next Generation ADAS Systems.“ Proceedings of 37th IEEE Conference on Computer Communications (INFOCOM 2018), Demo Session, Honolulu, HI, April 2018

- [6] S. Henning, P. Biemelt, N. Rüddenkau, S. Gausemeier, A. Trächtler, „A Simulation Framework for Testing a Conceptual Hierarchical Autonomous Traffic Management System including an Intelligent External Traffic Simulation“, Proceedings of the DSC 2018 Europe VR: New trends in Human in the Loop simulation and testing. Driving simulation and VR, S. 91-98, Frankreich, 2018 Driving Simulation Conference, Driving Simulation Association
- [7] P. Biemelt, S. Henning, N. Rüddenkau, S. Gausemeier, A. Trächtler, „A Model Predictive Motion Cueing Strategy for a 5-Degree-of-Freedom Driving Simulator with Hybrid Kinematics“, Proceedings of the DSC 2018 Europe VR: New trends in Human in the Loop simulation and testing. Driving simulation and VR, S. 79-85, Frankreich, 2018 Driving Simulation Conference, Driving Simulation Association
- [8] K. Abdalgawad, B. Hassan, J. Berssenbrücke, J. Stöcklein, M. Grafe, „A Modular Architecture of an Interactive Simulation and Training Environment for Advanced Driver Assistance Systems“, International Journal On Advances in Software, vol. 8, no. 1 & 2, pp. 247–261, Jun. 2015
- [9] K. Abdalgawad, M. Abdelkarim, B. Hassan, M. Grafe, I. Gräßler, „A modular architecture of a PC-based driving simulator for advanced driver assistance systems development“, 15th International Workshop on Research and Education in Mechatronics (REM), El Gouna, Ägypten: IEEE, Sep. 2014. DOI: 10.1109/REM.2014.6920237
- [10] A. Shaout, D. Colella, S. Awad, „Advanced driver assistance systems-past, present and future“, 2011 Seventh International Computer Engineering Conference (ICENCO'2011), Ägypten: IEEE, DOI: 10.1109/ICENCO.2011.6153935
- [11] A. Komzalov, N. Shilov, „Driver Assistance Systems: State-of-the-Art and Possible Improvements“, Proceedings of the 20th Conference of Open Innovations Association FRUCT, LETI University, St.Petersburg, Russland, 2014, ISSN 2305-7254, ISBN 978-952-68653-0-0
- [12] L. Wischhof, A. Ebner, H. Rohling, M. Lott, R. Halfmann, „SOTIS – A Self-Organizing Traffic Information System“, 57th IEEE Vehicular Technology Conference (VTC2003-Spring), Jeju, Südkorea: IEEE, Apr. 2003, pp. 2442–2446. DOI: 10.1109/VETEC.2003.1208829
- [13] P. A. Lopez; M. Behrisch; L. Bieker-Walz; J. Erdmann; Y.-P. Flöteröd; R. Hilbrich; L. Lücke; J. Rummel; P. Wagner; E. Wiesner, „Microscopic Traffic Simulation using SUMO“, in 21st IEEE International Conference 2018, Maui, USA, 02.11.2018, <https://elib.dlr.de/214092/>
- [14] A. Wegener, M. Piorkowski, M. Raya, H. Hellbrück, S. Fischer, J.-P. Hubaux, „TraCI: An Interface for Coupling Road Traffic and Network Simulators“, in 11th Communications and Networking Simulation Symposium (CNS 2008), Ottawa, Kanada: ACM, Apr. 2008, pp. 155–163. DOI: 10.1145/1400713.1400740
- [15] A. Varga, „The OMNeT++ Discrete Event Simulation System“, in European Simulation Multiconference (ESM 2001), Prag, Tschechien, Jun. 2001
- [16] S. Guan, R. E. De Grande, A. Boukerche, „Real-time 3D Visualization for Distributed Simulations of VANETs“, in 18th IEEE/ACM International Symposium on Distributed Simulation and Real Time Applications, Toulouse, France: IEEE, Oct. 2014, pp. 138–146. DOI: 10.1109/DS-RT.2014.25
- [17] D. Gruyer, O. Orfila, V. Judalet, S. Pechberti, B. Lusetti, S. Glaser, „Proposal of a Virtual and Immersive 3D Architecture dedicated for Prototyping, Test and Evaluation of Eco-Driving Applications“, IEEE Intelligent Vehicles Symposium (IV'13), Gold Coast, QLD, Australien: IEEE, Jun. 2013, pp. 511–518. DOI: 10.1109/IVS.2013.6629519
- [18] W. M. Griggs, R. H. Ordóñez-Hurtado, E. Crisostomi, F. Häusler, K. Massow, R. N. Shorten, „A Large-Scale SUMO-Based Emulation Platform“, IEEE Transactions on Intelligent Transportation Systems, vol. 16, no. 6, pp. 3050–3059, Dez. 2015. DOI: 10.1109/TITS.2015.2426056
- [19] F. Michaeler, C. Olaverri-Monreal, „3D Driving Simulator with VANET Capabilities to Assess Cooperative Systems: 3DSimVanet“, in IEEE Intelligent Vehicles Symposium (IV'17), Redondo Beach, CA, USA: IEEE, Jun. 2017, pp. 999–1004. DOI: 10.1109/IVS.2017.7995845
- [20] H. Prendinger, M. Miska, K. Gajananan, A. Nantes, „A Cyber-Physical System Simulator for Risk-Free Transport Studies“, Computer-Aided Civil and Infrastructure Engineering, vol. 29, no. 7, pp. 480–495, Aug. 2014. DOI: 10.1111/mice.12068
- [21] Y. Hou, Y. Zhao, A. Wagh, L. Zhang, C. Qiao, K. F. Hulme, C. Wu, A. W. Sadek, X. Liu, „Simulation-Based Testing and Evaluation Tools for Transportation Cyber-Physical Systems“, IEEE Transactions on Vehicular Technology, vol. 65, no. 3, pp. 1098–1108, März 2016. DOI: 10.1109/TVT.2015.2407614
- [22] P. Hiltjens, „ZeroMQ: Messaging for Many Applications“, O'Reilly Media, 2013
- [23] M. Haklay, P. Weber, „OpenStreetMap: User-Generated Street Maps“, IEEE Pervasive Computing, vol. 7, no. 4, pp. 12–18, Oct. 2008. DOI: 10.1109/MPRV.2008.80
- [24] C. Obermaier, C. Facci, „Observations on OMNeT++ Real-Time Behaviour“, in 4th OMNeT++ Community Summit (OMNeT++ 2017), Bremen, Germany: arXiv, Sep. 2017
- [25] J. Berssenbrücke, A. Trächtler, C. Schmidt, „Visualization of Headlight Illumination for the Virtual Prototyping of Light-Based Driver Assistance Systems“, Proceedings of the ASME 2015 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference, Boston, MA, USA, Aug. 2015

# Digitalisierung von Lichtverteilungen zur Hardware-in-the-Loop-Verifikation und Validierung von Matrixscheinwerfern

## Digitization of light distributions for hardware-in-the-loop verification and validation of matrix headlights

**Mirko Waldner M.Sc.,**

Univ.-Prof. Dr.-Ing. Prof. h.c. Dr. h.c. **Torsten Bertram**,

Lehrstuhl für Regelungssystemtechnik, Technische Universität Dortmund

### Kurzfassung

Der in diesem Beitrag vorgestellte Hardware-in-the-Loop-Prüfstand ermöglicht die Verifikation und Validierung kompletter realer hochauflösender Scheinwerfersysteme in virtuellen Testszenarien. Eine Fahrzeug-Umfeld-Simulation generiert hierfür die Steuersignale für das reale System. Der Steueralgorithmus des Scheinwerfers passt die Ausleuchtung an die aktuelle virtuelle Verkehrssituation an. Der Scheinwerfer beleuchtet eine Projektionsfläche im Lichtlabor. Die Lichtverteilung auf der Projektionsfläche wird durch ein Kamerasystem erfasst und damit digitalisiert. Das Bildverarbeitungssystem führt die aufgenommene Lichtverteilung in die Simulation zurück. Eine virtuelle Lichtquelle leuchtet das simulierte Umfeld mit der digitalisierten Lichtstärkenverteilung aus.

Der Ansatz ist echtzeitfähig und bildet die Helligkeits- und Farbverläufe der Ausleuchtung des realen Scheinwerfers realistisch ab. Damit kann der Ansatz als neues Entwicklungswerkzeug verwendet werden, um damit reale Testfahrten teilweise zu ersetzen.

### Abstract

The novel hardware-in-the-loop test stand in this paper enables the verification and validation of complete real high-resolution automotive headlights in virtual test scenarios. A simulation of the ego vehicle and environment generates the control signals for the real headlight. The headlight controller adapts the light distribution to the current virtual traffic situation. A camera system measures and digitizes the light distribution. The image processing system returns the received light distribution to the simulation. A virtual light source illuminates the simulated environment with the digitized light distribution.

This approach is real-time capable and realistically reproduces the intensity and color gradients of the illumination of the real headlight. Thus, the approach can be used as a new development tool to partially replace real test drives.

## 1. Hardware-in-the-Loop-Evaluation von Matrix-Scheinwerfern

Aktuelle automobile Scheinwerfersysteme sind aus einer Vielzahl verschiedener Lichttechnologien aufgebaut [1]. Damit sollen die Vorteile der unterschiedlichen Lichttypen optimal kombiniert werden. Die Superposition der Lichtverteilungen der einzelnen Module ergibt die Ausleuchtung vor dem Egofahrzeug. Diese kann adaptiv an die aktuelle Verkehrssituation angepasst werden. Dies wird durch individuelle Helligkeitsanpassungen einzelner Lichtpixel erreicht. Hierfür sind die einzelnen Lichtmodule aus einer Matrix von Lichtquellen aufgebaut, die individuell gesteuert werden können. Adaptive Lichtfunktionen wie das blendfreie Fernlicht sind damit realisiert [2].

Die abschließende Verifikation und Validierung in der Entwicklung jedes Scheinwerfersystems findet in realen nächtlichen Testfahrten statt. In diesem Evaluationsschritt wird die Funktionalität der realen Systemkomponenten unter Einfluss der Fahrdynamik des Egofahrzeugs untersucht und bewertet. Durch die zunehmende Komplexität von Scheinwerfern und die Erhöhung der Auflösung der Lichtmatrizen wird sich die Länge der benötigten realen Testkilometer in Zukunft weiter erhöhen. Reale Testfahrten für Scheinwerfersysteme können nur bei, für die zu testende Lichtfunktion, passenden Witterungen und Lichtverhältnissen durchgeführt werden. Außerdem sind sie nicht exakt reproduzierbar und benötigen für Evaluationen im öffentlichen Straßenverkehr ein Scheinwerfersystem mit Straßenzulassung.

Die vorgestellte Methode der echtzeitfähigen Digitalisierung von Lichtverteilungen ermöglicht eine Hardware-in-the-Loop(HiL) Evaluation des kompletten realen Scheinwerfers im Lichtlabor. Dies dient als Ergänzung zu realen Testfahrten mit dem Ziel, diese teilweise durch HiL-Tests zu ersetzen. Der Ansatz ordnet sich im Entwicklungsablauf direkt vor der realen Testfahrt ein (siehe Bild 1) und bildet damit den Übergang zwischen Labor- und Feldtests.

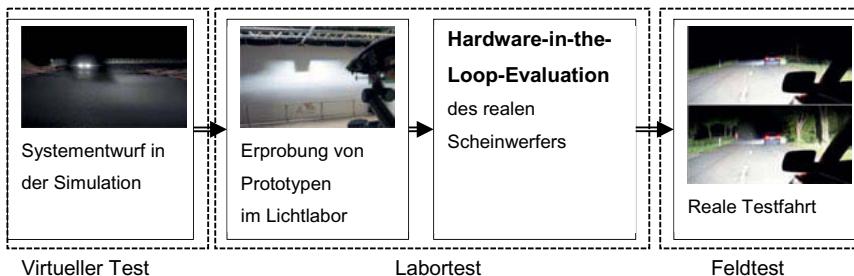


Bild 1: Einordnung des neuen Ansatzes in den bisherigen Entwicklungs- und Evaluationsablauf von Scheinwerfersystemen (Quelle rechtes Bild [3]).

Durch die Digitalisierung wird es möglich die Lichtverteilung des realen Scheinwerfers in einer virtuellen Welt realistisch zu visualisieren. Damit kann der reale Scheinwerfer aus einer Simulation angesteuert und seine Lichtverteilung in diese zurückgeführt werden. Es ist nun möglich, in virtuellen Testszenarien den realen Scheinwerfer als Lichtquelle zu verwenden.

Mit der Methode der Digitalisierung kann die Verifikation und Validierung des realen Systems im Lichtlabor unter reproduzierbaren Bedingungen zu jeder Tageszeit durchgeführt werden. Als Erweiterung zu realen Testfahrten können in virtuellen Szenarien Systeme getestet und Parameterstudien durchgeführt werden, für die noch keine Straßenzulassung vorliegen. Außerdem kann das System in virtuellen Szenarien evaluiert werden, welche sich in der Realität nur mit großem Aufwand realisieren lassen. Die Methode ermöglicht eine gezielte Analyse kritischer Situationen und vereinfacht damit die Systemoptimierung und das Finden von Entwurfsfehlern.

Es existieren verschiedene Konzepte für HiL-Prüfstände für Scheinwerfer [4]. Die Konzepte unterscheiden sich darin, ob der Scheinwerfer mechanisch bewegt werden kann und welche Größen gemessen werden können. Das Konzept dieses Beitrages hat als Innovation die echtzeitfähige Rückführung der kompletten Lichtverteilung in die virtuelle Welt und ermöglicht somit den ganzen Scheinwerfer im Loop zu betreiben. Realisiert wird dies über die indirekte Messung der Helligkeit mit einem Kamerasystem. Die Messung der Lichtverteilung von Scheinwerfern mit Kameras ist ein bekannter Ansatz, wobei die Methoden nicht echtzeitfähig sind. Das in [5] gezeigte Verfahren berechnet eine individuelle Tabelle mit Lichtstärken für jeden Wert jedes Pixels. Dieser Ansatz erfordert viele Speicherzugriffe und viel Speicherplatz. Der Ansatz aus [6] verwendet als Messinstrument eine Leuchtdichtekamera, welche optische Filter der Wellenlänge verwenden. Dies ist genau, aber durch das Umschalten der Filter nicht echtzeitfähig. In dem vorliegenden Beitrag wird den Messfehler der Lichtstärke vor einer Inbetriebnahme identifiziert und minimiert. Damit können die Parameter einer Korrekturfunktion bestimmt werden, welche parallel auf alle Pixel angewendet werden kann. Somit wird als Innovation Echtzeitfähigkeit bei optimaler Messgenauigkeit erreicht.

In Kapitel 2 werden die Komponenten des Prüfstands vorgestellt. Hier wird außerdem der Informationsfluss zwischen den Modulen beschrieben. Kapitel 3 dokumentiert die Steuerung des realen Scheinwerfers aus der Simulation heraus. In Kapitel 4 wird die Messung und Verarbeitung der Lichtverteilung aufgezeigt. Anschließend wird ihre Visualisierung erläutert. Die Evaluation des Ansatzes findet sich in Kapitel 5 und Kapitel 6 schließt den Beitrag mit einer Zusammenfassung und einem Ausblick ab.

## 2. Systemkomponenten des Hardware-in-the-Loop-Prüfstands

Der HiL-Prüfstand gliedert sich in drei Hauptkomponenten, welche der Aufbau im Labor, die Bildverarbeitung und die virtuelle Welt sind.

Der Aufbau im Lichtlabor besteht wiederrum aus drei Komponenten. Zum einen aus dem zu testenden Scheinwerfer, einer Projektionswand und dem Kamerasytem. Die Lichtstärkenverteilung des Scheinwerfers wird vom Messsystem indirekt vermessen. Hierzu leuchtet der Scheinwerfer, wie in Bild 2, auf eine Projektionsfläche, welche vom Kamerasytem abgefilmt wird. Die aufgenommenen Bilder werden anschließend in der Bildverarbeitungskomponente bearbeitet.



Bild 2.: Indirekte Messung der Lichtverteilung.

Im ersten Schritt der Bildverarbeitung wird das Rauschen in den Bildern unterdrückt und Störungen korrigiert. Anschließend werden aus den Pixelwerten die Lichtstärkenverteilung errechnet, welche vom Scheinwerfer abgestrahlt wird. Hierfür wurde das Kamerasytem vor der Inbetriebnahme kalibriert und justiert. Unter Auswertung einer Referenz der Lichtstärkenverteilung, welche von einem Photometer direkt und absolut gemessen wurde, wird während der Inbetriebnahme der Messfehler des Systems bestimmt. Durch die Optimierung der Struktur und der Parameter der Umrechnungsfunktion wird der Messfehler während der Justierung des Systems minimiert. Somit kann aus dem aufgenommenen Bild die abgestrahlte Lichtstärkenverteilung des Scheinwerfers rekonstruiert werden.

Das Ergebnis der Bildverarbeitung ist ein Farbbild, in dem die abgestrahlte Lichtstärke des Scheinwerfers goniometrisch für jeden Farbkanal gespeichert ist. Die Lichtquelle in der virtuellen Welt nutzt diese Datenbank, um die Abstrahlcharakteristik des Scheinwerfers dreidimensional wiederzugeben. Dazu wird projiziertes Textur-Mapping [7] verwendet, mit dem zweidimensionale Texturen echtzeitfähig auf dreidimensionale Oberflächen gemappt werden. Dieser Ansatz ist das Standardverfahren zur echtzeitfähigen Lichtsimulation [8]. Die virtuelle Lichtquelle befindet sich in einer Simulation des Egofahrzeugs und seines Umfelds.

Die virtuelle Welt wird somit vom digitalisierten Scheinwerfer beleuchtet. Eine Sensorsimulation erfasst alle relevanten Daten zur Scheinwerfersteuerung, wie z. B. den Lenkwinkel des Egofahrzeugs oder Gegenverkehr im Lichtkegel. Diese Daten werden in das Format der Fahrzeugkommunikation umgewandelt und über den Kommunikationsbus an den realen Scheinwerfer versendet. Somit hat das Scheinwerfersystem die gleichen Eingangsgrößen wie im realen Fahrzeug. Das Steuergerät im Scheinwerfer berechnet aus den Daten die optimale Lichtverteilung für die virtuelle Umgebungssituation.

In Bild 3 sind die Systemkomponenten und der Informationskreislauf zwischen den Teilsystemen als Gesamtübersicht dargestellt.

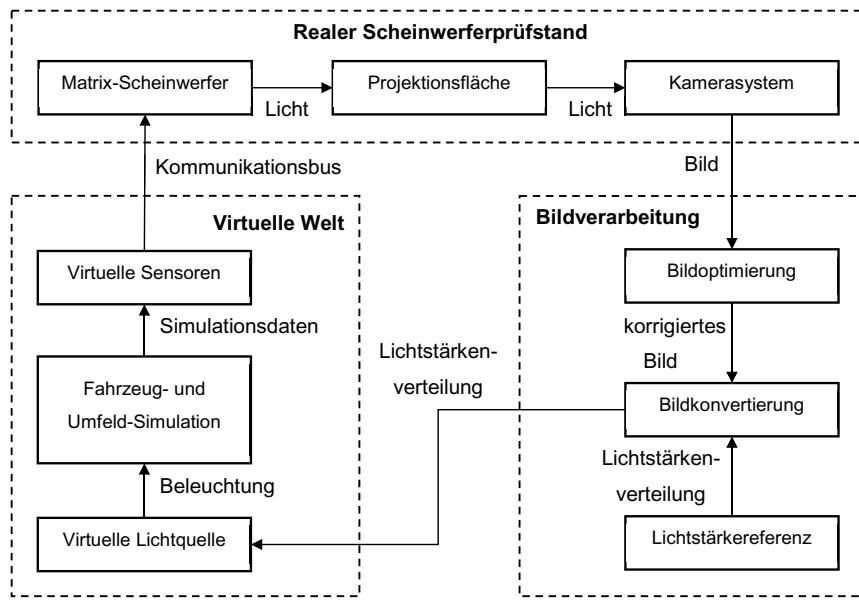


Bild 3.: Übersicht über die Systemkomponenten und den Informationsfluss.

### 3. Steuerung des Matrix-Scheinwerfers aus der virtuellen Welt

Der reale Matrix-Scheinwerfer wird über die Fahrzeug-Kommunikation gesteuert. Von der Simulation werden alle Steuergeräte des Egofahrzeugs nachgebildet, die für den Scheinwerfer relevant sind. Das umfasst alle Steuergeräte, welche den Scheinwerfer direkt steuern und Informationen für diesen über den Kommunikationsbus versenden. Somit ist die Ansteuerung des Systems wie im realen Fahrzeug. Hierfür müssen in der virtuellen Welt alle relevanten Größen simuliert und mit dem richtigen Format versendet werden.

Die Datenaufnahme der benötigten Größen kann durch die Implementierung der realen Messeinrichtung erfolgen. Die Datenverarbeitung der Erfassung des Fahrzeugumfeldes nach [2] für adaptive Lichtfunktionen kann direkt in die Simulation integriert werden, da sich die gleichen Eingangsgrößen generieren lassen. Durch das verwendete Beleuchtungsmodell [9] und die Eigenschaften der virtuellen Kamera unterscheidet sich die Simulation aber von der Realität. Deswegen kann eine Auswertung der simulierten Sensordaten andere Ergebnisse als in der Realität generieren. Für ein sicheres Testen des Scheinwerfers wird daher folgende Approximation der Erfassung des Umfeldes verwendet. Der Ansatz ist die Objekte direkt zu erfassen und die Unsicherheit der realen Erfassung nachträglich zu modellieren.

Jedes Objekt, wie Gegenverkehr, Gefahrenstellen oder Straßenschilder, wird in der Simulation als Objekt mit dem Parametervektor  $\mathbf{o} \in \mathbb{R}^7$  verwaltet. Der Vektor enthält die Klasse  $c$  des Objektes und seine Position  $(x_F \ y_F)^T$  im Fahrzeugkoordinatensystem  $\mathcal{K}$ . Außerdem enthält der Vektor die Höhe  $h$  und Breite  $w$  des umschließenden minimalen Rechtecks. Die Höhe und Breite des Rechtecks kann in Abhängigkeit der Vertrauenswürdigkeit der Sensoren durch Addition von  $\Delta h$  und  $\Delta w$  modifiziert werden. Der komplette Parametervektor  $\mathbf{o}$  ist damit:

$$\mathbf{o} = (c \ x_F \ y_F \ h \ \Delta h \ w \ \Delta w)^T. \quad (1)$$

Zur Nachbildung der Erfassung des Umfeldes werden in jedem diskreten Zeitschritt der Simulation alle Objekte und deren Parameter im Bereich der Lichtausbreitung des Egofahrzeugs erfasst. Dies ist in Bild 4 für ein entgegenkommendes Fahrzeug gezeigt. Anschließend wird die Sichtbarkeit für den Sensor überprüft und alle verdeckten Objekte verworfen. Abschließend wird die Verlässlichkeit der Erfassung in der korrespondierenden realen Situation bestimmt bzw. simuliert.

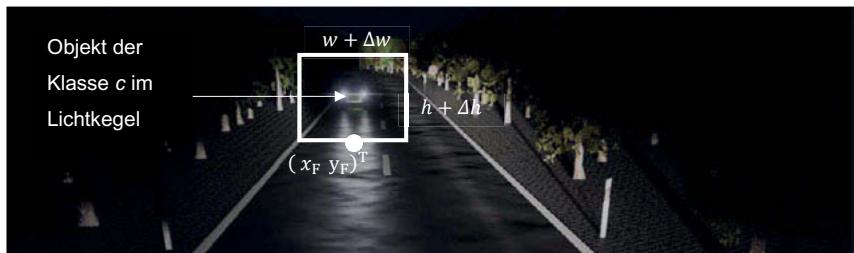


Bild 4.: Relevante Größen der Erfassung des Umfeldes zur Scheinwerfersteuerung.

Die Steueralgorithmen für Matrixscheinwerfer verändern nach [2] die Größe des Hüllkörpers von Objekten mit  $\Delta h$  und  $\Delta w$  um die Funktionalität der Lichtfunktion abzusichern. Beispielsweise wird bei einer unsicheren Erfassung vom Gegenverkehr der abzudunkelnde Bereich vergrößert, um Blendungen sicher zu vermeiden. Um diese Sicherheitsfunktion zu testen, kann in der Simulation die Größe des Hüllkörpers entweder direkt vorgegeben oder die Unsicherheit simuliert werden. Damit kann der Einfluss von verschiedenen Hüllkörpergrößen auf die Funktionalität untersucht werden.

Aus den Parametern aller detektierten Objekte erstellt die Simulation die entsprechenden Pakete zur Kommunikation über das Bussystem. Zusätzlich werden die relevanten Größen des Egofahrzeugs, wie z. B. der Lenkwinkel und die Geschwindigkeit, an den Scheinwerfer geschickt. Damit stehen dem Steuergerät des Scheinwerfers dieselben Informationen im selben Format wie in der Realität zur Verfügung, um die abgestrahlte Lichtverteilung an die Verkehrssituation zu adaptieren.

#### 4. Digitalisierung und Visualisierung der Lichtverteilung

Die Rückführung der realen Lichtverteilung in die virtuelle Welt besteht aus zwei Schritten. Der Erste ist die indirekte Messung der vom Scheinwerfer abgestrahlten Lichtstärkenverteilung inklusive der Farbinformationen. Der Zweite ist die Ausleuchtung der virtuellen Welt nach den gemessenen Daten, um dieselbe Beleuchtung wie in der Realität zu erhalten.

Vor Inbetriebnahme muss das Messsystem kalibriert und justiert werden [10]. Mit diesem Vorgang werden die relative Position und Ausrichtung der Kamera zum Scheinwerfer bestimmt. Das ergibt die Koordinatentransformation  ${}_{\mathcal{K}}\mathbf{T}^{\mathcal{S}} \in \mathbb{R}^{4 \times 4}$  vom Kamerakoordinatensystem  $\mathcal{K}$  in das Scheinwerferkoordinatensystem  $\mathcal{S}$ . Damit kann jedem Pixel der Kamera eine Abstrahlrichtung des Scheinwerfers eindeutig zugeordnet werden.

Das Kamerasytem erfasst ein Farbbild  $H_{\text{RGB}} \in \mathbb{R}^{m \times n \times 3}$  mit  $m$  Zeilen,  $n$  Spalten und 3 Farbkanälen (rot, grün, blau). Jedes Element  $H_{i,j} \in [0,1]$  aus  $H_{\text{RGB}}$  ist die Anregung eines Sensorelementes. Die Bildverarbeitung berechnet aus  $H_{\text{RGB}}$  mit der Umrechnungsfunktion  $\mathbf{f}(H_{\text{RGB}})$  die abgestrahlte Lichtstärkenverteilung  $I_{v,c} \in \mathbb{R}^{m \times n \times 3}$  des Scheinwerfers für alle drei Farbkanäle:

$$I_{v,c} = \mathbf{f}(H_{\text{RGB}}). \quad (2)$$

Die Umrechnungsfunktion muss in Abhängigkeit der verwendeten Kamera und der Laborbedingungen gewählt werden, um den Messfehler zu reduzieren. Die verwendete Hardware bestimmt nach [5] die nichtlineare Anregungsfunktion des Kamerasensors und damit die optimale Umrechnungsfunktion. Außerdem haben die Reflexionseigenschaften insbesondere die Richtungsabhängigkeit der Projektionsfläche Einfluss auf  $\mathbf{f}(H_{\text{RGB}})$ . Mit Gleichung (2) wird aus der Anregung  $H_{i,j}$  die Lichtstärke  $I_{v,c,i,j} \in [0, I_{v,\max}]$  jedes Elements aus  $I_{v,c}$  berechnet, welche die Anregung auslöst. Hierfür wurde durch Vergleich mit einer Referenz-Lichtstärkenverteilung der Messfehler durch die Reflexionseigenschaften der Projektionswand und des Sensors der Kamera identifiziert. Die Referenz sind Messdaten, welche mit einem Goniophotometer aufgenommen wurden. Durch Minimierung des Fehlers wurden die Parameter  $\mathbf{x} = (x_1 \ x_2 \ x_3 \ x_4)^T$  zur optimalen Umrechnung bestimmt. Die verwendete Umrechnungsfunktion  $f_V(\tilde{H}_{i,j})$  in diesem Beitrag ist:

$$\tilde{H}_{i,j} = \begin{cases} H_{i,j} & \text{für } H_{i,j} \geq x_2 \\ 0 & \text{für } H_{i,j} < x_2 \end{cases} \quad (3)$$

$$I_{v,c,i,j} = f_V(\tilde{H}_{i,j}) = x_1 (\tilde{H}_{i,j} - x_2)^{x_3} + x_4. \quad (4)$$

Die Ausleuchtung in der Simulation wird über das projizierte Textur-Mapping [7] mit dem Verfahren nach [8] realisiert. Dieser Ansatz wird nun auf drei Farbkanäle erweitert. Die drei Lichtstärkenverteilungen jedes Farbkanals wirken hiermit als eine Art Blende vor drei virtuellen punktförmigen Lichtquellen. Jede dieser Punktlichtquellen strahlt mit der Lichtstärke  $I_{v,\max,\text{sim}}$ . Die Textur gibt damit die relative Helligkeit vor, welche in die entsprechende Richtung abgestrahlt wird. Jede Lichtquelle entspricht einem der drei Farbkanäle in der Simulation. Die Ausleuchtung der drei farbigen Quellen wird additiv überlagert, wodurch sich die angezeigte Farbe ergibt. Dies setzt die Nutzung eines additiven und linearen Farbraumes voraus. Damit lassen sich die Farbverläufe innerhalb der Lichtverteilung darstellen, welche durch die chromatische Aberration des Linsensystems des Scheinwerfers verursacht werden.

Unter Verwendung von  $\kappa T^S$  kann der Zugriff auf jedes Texturelement so durchgeführt werden, dass jede Abstrahlrichtung der virtuellen Lichtquelle der des realen Scheinwerfers entspricht. Befindet sich beispielsweise die Kamera direkt über dem Scheinwerfer, muss der Datenzugriff

in der Simulation nach unten verschoben werden, um die Verschiebung auszugleichen. Um die aufgenommene Lichtstärkenverteilung realistisch darstellen zu können, muss die Simulation kalibriert werden. Die virtuelle maximale Lichtstärke  $I_{v,max,sim}$  muss der realen maximalen Lichtstärke  $I_{v,max}$  des Scheinwerfers entsprechen:

$$I_{v,max,sim} := I_{v,max}. \quad (5)$$

Entsprechen bedeutet, dass beide Quellen den gleichen visuellen Eindruck erzeugen. Mit dieser Festlegung kann  $I_{v,c,i,j}$  aus (4) in die relative Lichtstärke  $\tilde{I}_{v,c,i,j}$  umgewandelt werden:

$$\tilde{I}_{v,c,i,j} = \frac{I_{v,c,i,j}}{I_{v,max}}. \quad (6)$$

Eine Textur aus relativen Lichtstärken nach (6) kann zur Lichtsimulation mit projiziertem Textur-Mapping verwendet werden. Der weitere Ablauf entspricht dem Standardvorgehen und ist in [7] und [8] erläutert.

In Bild 5 ist der komplette Ablauf der Rückführung ausgehend vom Scheinwerfer hin zur Beleuchtung auf der Straße dargestellt.

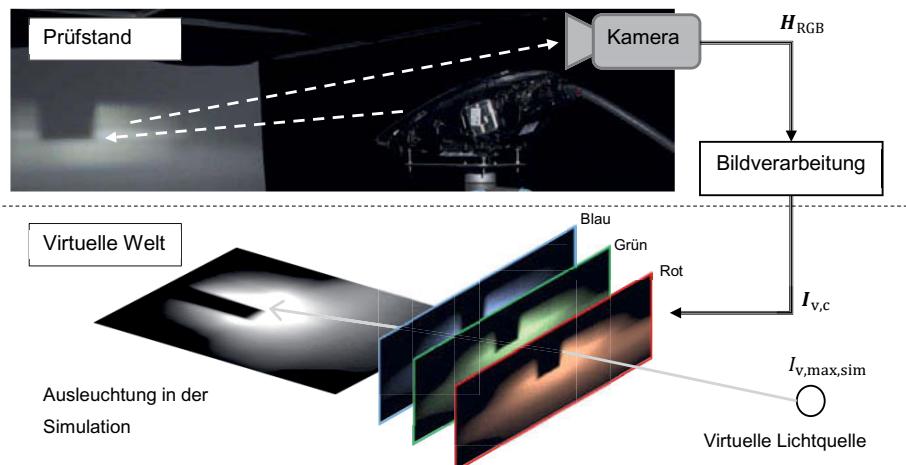


Bild 5: Ablauf der Rückführung der realen Lichtverteilung in die virtuelle Welt.

## 5. Evaluation des Entwicklungswerkzeugs

Die Echtzeitfähigkeit der vorgestellten Methode wird mit einer heterogenen Softwarearchitektur erreicht. Die Architektur hat als Hauptkomponenten Unity 2018.3 [11] zur Lichtsimulation und OpenCV 4.0.1 [12] zur Bildverarbeitung. Die Bildverarbeitung wird unter Verwendung von Cuda 10 [13] parallelisiert und auf der GPU ausgeführt. Die Bildentstörungs- und Umrechnungszeit  $t_{\text{run,ip}}$  für eine Bild mit  $900 \times 500$  Pixeln ist  $t_{\text{run,ip}} \leq 30$  ms auf einer GTX 1080 Ti. Der Hauptteil der Rechenzeit wurde zur Rauschunterdrückung nach [14] verwendet. Dazu kommt eine Verzögerung  $t_{\text{run,com}}$  durch die Versendung und Konvertierung der Daten von OpenCV nach Unity, welche in der verwendeten Implementierung  $t_{\text{run,com}} \leq 75$  ms ist. Die Simulation in Unity erreicht auf demselben Rechner wie die Umrechnung eine Bildrate von 60 fps. Mit dieser Implementierung ist die Verzögerung durch die Rückführung in der Simulation nicht wahrnehmbar und die Methode somit echtzeitfähig.

In Bild 6 sind Ausleuchtungen der virtuellen Umgebung mit einem digitalisierten Scheinwerfer dargestellt. Die Lichtverteilung fügt sich konsistent in die Simulation ein und ist nicht als Fremdkörper auffällig. Somit können rein virtuelle und digitalisierte Lichtquellen in einer Simulation zusammen verwendet werden, ohne dass diese vom Betrachter zu unterscheiden sind.



Bild 6: Visualisierung der Ausleuchtung des digitalisierten rechten Scheinwerfers.

Der subjektive visuelle Eindruck der Ausleuchtung in der Simulation entspricht dem in der Wirklichkeit, wenn die Simulation korrekt kalibriert wurde. Die Helligkeits- und Farbverläufe innerhalb der Lichtverteilung werden realitätsnah wiedergegeben. Das umfasst die durch chromatische Aberration hervorgerufenen bläulichen Ränder der Lichtverteilung und Inhomogenitäten durch die Überlappung der Pixel. Diese Farbverläufe sind in Bild 7 abgebildet.

Der Ansatz ermöglicht somit die Evaluation des realen Scheinwerfers in verschiedenen Testszenarien. Bild 7 zeigt die Evaluation der Lichtverteilung auf einer Bewertungswand, welche die Beleuchtungszonen der Richtlinie [15] der Wirtschaftskommission für Europa der Vereinten Nationen (UNECE) nachbildet. Hier ist zu erkennen, dass auch die räumliche Ausbreitung der Lichtverteilung realistisch visualisiert wird. Die Abstrahlcharakteristik entspricht der des realen Systems.

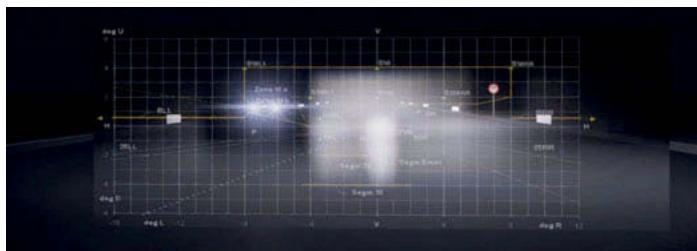


Bild 7: Bewertung der realen Lichtverteilung in der Simulation nach den UNECE-Richtlinien [15]

## 6. Zusammenfassung und Ausblick

Die vorgestellte Methode ermöglicht die echtzeitfähige Digitalisierung und Visualisierung von Lichtverteilungen von realen Scheinwerfern in virtuellen Testszenarien. Die Ausleuchtung der virtuellen Welt ist realitätsnah in der Helligkeit, dem Farbverlauf und der räumlichen Ausbreitung. Damit sind Hardware-in-the-Loop-Verifikationen und Validierungen von kompletten Scheinwerfern möglich und reale Testfahrten können teilweise durch HIL-Evaluationen ersetzt werden.

Der vorgestellte Ansatz ermöglicht eine visuelle Bewertung der Lichtverteilung. In den folgenden Arbeiten wird der Ansatz auf Eignung zur echtzeitfähigen numerischen Bewertung untersucht. Das Ziel ist die Entwicklung eines HIL-Prüfstandes, welcher sowohl die echtzeitfähige qualitative visuelle Bewertung als auch die Erstellung von quantitativen Rankings von realen Scheinwerfern ermöglicht.

## 7. Danksagung

Wir danken der Firma HELLA GmbH & Co. KGaA für die freundliche Unterstützung und die gute Zusammenarbeit. Außerdem bedanken wir uns für die Zurverfügungstellung des Matrixscheinwerfers und seiner photometrischen Messdaten. Dieses Vorhaben wird aus Mitteln des Europäischen Fonds für regionale Entwicklung (EFRE) unter dem Förderkennzeichen EFRE-0800850 gefördert.

## Literaturverzeichnis

- [1] J. Moisel, „Requirements for future high resolution (ADB) modules,“ in 11th International Symposium on Automotive Lighting – ISAL, 2015.
- [2] B. Hummels, Blendfreies Fernlicht, Cuvillier, 2009.
- [3] HELLA GmbH & Co. KGaA, „Increased detection distance by comparing conventional dipped beam with glare-free highbeam technology,“ 2019.
- [4] M. Waldner, M. Krämer und T. Bertram, „Optimierung des Entwicklungsprozesses von Scheinwerfersystemen durch mechanische Nachbildung der Fahrdynamik,“ in VDI Fachtagung Mechatronik 2019, ISBN 973-3-945437-05-6, 2019.
- [5] I. Lewin und J. O'Farrell, „Luminaire Photometry Using Video Camera Techniques,“ Journal of the Illuminating Engineering Society, Bd. 28, Nr. 1, pp. 57-63, 1999.
- [6] S. Bogdanow, M. Marutzkys, B. Kleinert und K. Schulze, „Testen am gesamten Lichtsystem,“ ATZ - Automobiltechnische Zeitschrift, Bd. 11, Nr. 115, 2013.
- [7] M. Segal, C. Korobkin, R. v. Widenfelt, J. Foran und P. Haeberli, „Fast Shadows and Lighting Effects Using Texture Mapping,“ SIGGRAPH Comput. Graph., Bd. 2, Nr. 26, 1992.
- [8] P. Lecocq, J. Kelada und A. Kemeny, „Interactive Headlight Simulation,“ in Proceedings of the DSC'99 Driving Simulation Conference, 1999.
- [9] B. Burley, „Physically Based Shading at Disney,“ in ACM SIGGRAPH Practical Physically Based Shading in Film and Game Production course), 2012.
- [10] M. Waldner, M. Krämer und T. Bertram, „Hardware-in-the-Loop-Simulation of the light distribution of automotive Matrix-LED-Headlights,“ in IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), 2019 - Angenommen.
- [11] Unity Technologies, „Unity 2019,“ Unity Technologies.
- [12] G. Bradski, „The OpenCV Library,“ Dr. Dobb's Journal of Software Tools, 2000.
- [13] J. Nickolls, I. Buck, M. Garland und K. Skadron, „Scalable Parallel Programming with CUDA,“ Queue, Bd. 2, Nr. 6, 2008.
- [14] A. Buades, B. Coll und J. Morel, „A non-local algorithm for image denoising,“ in IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), 2005.
- [15] UNECE, „UN Regulation No. 123 - Adaptive front-lighting systems (AFS),“ UNECE, 2016.

# Hardware-in-the-Loop Simulation of High-Definition Headlamp Systems

M.Sc. Nico Rüddenklau, Dr.-Ing. Sandra Gausemeier,  
Prof. Dr.-Ing. habil. Ansgar Trächtler,  
Heinz Nixdorf Institut, Universität Paderborn

## Zusammenfassung

Moderne hochauflösende Scheinwerfer-Systeme heben die Möglichkeiten zur Umsetzung neuer Lichtfunktionen auf den nächsten Level. Zur Ausschöpfung der neu gewonnenen Potentiale muss das Scheinwerfer-Steuergerät jedoch komplexere Algorithmen und Sensorgrößen verarbeiten. Der Aufwand zur Entwicklung der Steuergerätesoftware steigt somit erheblich. Aufgrund der zunehmenden dynamischen Anteile neuartiger Lichtfunktionen kann die Erprobung darüber hinaus nur zu geringen Anteilen im Lichtkanal durchgeführt werden und muss anhand von Prototypen durch zeitaufwendige und kostenintensive Nachtfahrten erfolgen. Außerdem lassen sich reale Fahrsituationen aufgrund der vielen Umwelteinflüsse nicht reproduzieren. Hieraus motiviert wird in diesem Beitrag eine echtzeitfähige Hardware-in-the-Loop Simulation hochauflösender Scheinwerfersysteme vorgestellt, durch welche diese erstmalig in virtuellen Nachtfahrten entwickelt und analysiert werden können.

## Abstract

Modern high-definition headlamp systems raise the possibilities for implementing new lighting functions to the next level. In order to exploit the newly gained potential, however, the headlamp control unit must process more complex algorithms and sensor information. The effort required to develop the control unit software thus rises considerably. Moreover, due to the increasing dynamic components of new types of lighting functions, only a fraction of the testing can be performed in the light channel and must be done with prototypes by time-consuming and cost-intensive night drives. In addition, real driving situations cannot be reproduced due to the many environmental influences. Motivated by this, this article presents a real-time hardware-in-the-loop simulation of high-definition headlamp systems, through which these can be developed and analyzed for the first time in virtual night drives.

## 1. Einleitung und Motivation

Die Einführung hochauflösender (auch: HD  $\triangleq$  High Definition) Scheinwerfer in die Automobilindustrie erweitert die Möglichkeiten neuartiger Lichtfunktionen durch die gestiegerte Flexibilität und Präzision erheblich. Während schon heute Matrix-Systeme mit etwa 100 unabhängigen Lichtquellen in Serienfahrzeugen zu finden sind, werden zukünftige Fahrzeugscheinwerfer mit Auflösungen von 30.000 Pixeln und mehr ausgestattet sein [1]. Jede Einheit ist in ihrer Helligkeit darüber hinaus kontinuierlich regelbar. Bei der optischen Auslegung der einzelnen Lichtquellen werden die von ihnen ausgeleuchteten Raumwinkelbereiche fein voneinander separiert. Auf diese Weise kann die

Gesamtlichtverteilung in den Grenzen der Auflösung und Dynamik des Scheinwerfersystems zu jedem Zeitpunkt frei gewählt werden.

Dieses neu gewonnene Potential moderner Scheinwerfer kann jedoch nur dann ausgeschöpft werden, wenn ihre Steuergeräte die einzelnen Pixel bzw. Lichtquellen abhängig von der derzeit vorliegenden Fahr- und Umgebungssituation adäquat ansteuern. Aufgrund des hochdimensionalen Stellgrößenraums unterliegt die Implementierung und Validierung neuer Lichtfunktionen abseits der Simulation einem erheblichen Testaufwand. Erschwerend hinzu kommt die hohe Dynamik moderner Lichtfunktionen, wie des blendfreien Fernlichts, Markierungslichts und Kurvenlichts, welche statische Tests im Lichtkanal ausschließt und zeit- und kostenintensive Nachtfahrten erfordert. Hierbei ist wiederum die Reproduzierbarkeit, insbesondere aufgrund varierender Umgebungsbedingungen, nicht gegeben.

Motiviert durch die genannten Schwierigkeiten wird in diesem Beitrag eine Hardware-in-the-Loop (HIL) Fahrersimulation hochauflösender Scheinwerfersysteme vorgestellt, welche die Entwicklungszeiten und -kosten bei der Einführung neuer Lichtfunktionen deutlich reduzieren und die Notwendigkeit realer Nachtfahrten minimieren soll. Das Scheinwerfersteuergerät stellt im HIL-Verbund die Testhardware dar. Die Vielzahl der Lichtquellen hochauflösender Systeme erweist sich unter den Echtzeitanforderungen einer Fahrersimulation bei der Berechnung des Lichts in der virtuellen Szene als besonders herausfordernd.

## 2. Stand der Technik

Die Einführung des blendfreien Fernlichts in 2010 zeigte die Potentiale situationsadaptiver Lichtfunktionen in eindrucksvoller Weise auf [2]. Während die Adaptivität der Scheinwerfer anfangs durch mechanisches Schwenken erreicht wurde, hat die Digitalisierung auch diesen Sektor in den vergangenen Jahren durchzogen. Dennoch dauerte es viele Jahre, bis die Idee eines Pixellichts, welche erstmalig auf der PAL (heute ISAL) Konferenz in 2001 vorgestellt wurde, zur automobilen Serienreife heranwuchs [3]. Erst seit 2013 werden mechanisch aktivierte Scheinwerfersysteme durch LED-Matrix-Lösungen abgelöst, welche ihre Lichtverteilungen ausschließlich durch das gezielte Dimmen einzelner LEDs adaptieren [4]. Das in diesem Beitrag als Anwendungsbeispiel dienende HD84-System mit 84 LEDs pro Matrix wurde 2016 eingeführt [5].

Mit der Leistungsfähigkeit der Scheinwerfersysteme wächst auch der Entwicklungsaufwand. Hierbei stellt die Notwendigkeit einer dunklen Umgebung sowie die Verfügbarkeit und Reproduzierbarkeit geeigneter Fahrszenarien ein besondere Herausforderung für die schnelle Marktreife neuer Scheinwerferkonzepte dar. Um diesen Problemen zu begegnen, stellten Lecocq et al. 1999 die erste echtzeitfähige Scheinwerfer-Simulation vor [6]. Wenige Jahre später wurden grafisch exaktere Ansätze durch die Verwendung von Per-Fragment-Lighting präsentiert [7,8]. Basierend auf diesen Arbeiten wurden verschiedene dynamische Lichtfunktionen erprobt [9,10,11,12].

Alle genannten Ansätze haben gemein, dass sie einige wenige Lichtquellen mit statischen Lichtstärkeverteilungen modellieren. Die Adaptivität wird durch Schwenken und Ein- und Ausschalten der Lichtquellen erzeugt. Hochauflösende Matrix-Systeme funktionieren

grundlegend anders und bedürfen deshalb neuartiger Modellierungsansätze. Die erste echtzeitfähige Simulation von hochauflösenden Scheinwerfersystemen wurde 2018 vorgestellt [13]. Darin beschriebene Ergebnisse bilden die Grundlage für die hier vorgestellte Gesamtarchitektur einer Nachtfahrt-Simulation mit Scheinwerfer-Steuergerät im HiL-Betrieb.

### 3. Architektur

Die Architektur der Simulation besteht aus vier Hauptkomponenten. Diese sind die physikalische Simulation, die visuelle Simulation, die Schnittstelle zum Fahrer und das Scheinwerfer-Steuergerät als Testkomponente der HiL-Simulation. Während letzteres als Blackbox betrachtet wird, können die übrigen Komponenten weiter untergliedert werden. Eine Gesamtübersicht der Architektur wird in Abbildung 1 veranschaulicht. Die Strukturierung, die jeweiligen Funktionen und die Schnittstellen zwischen den einzelnen Bestandteilen werden in den folgenden Abschnitten näher beschrieben.

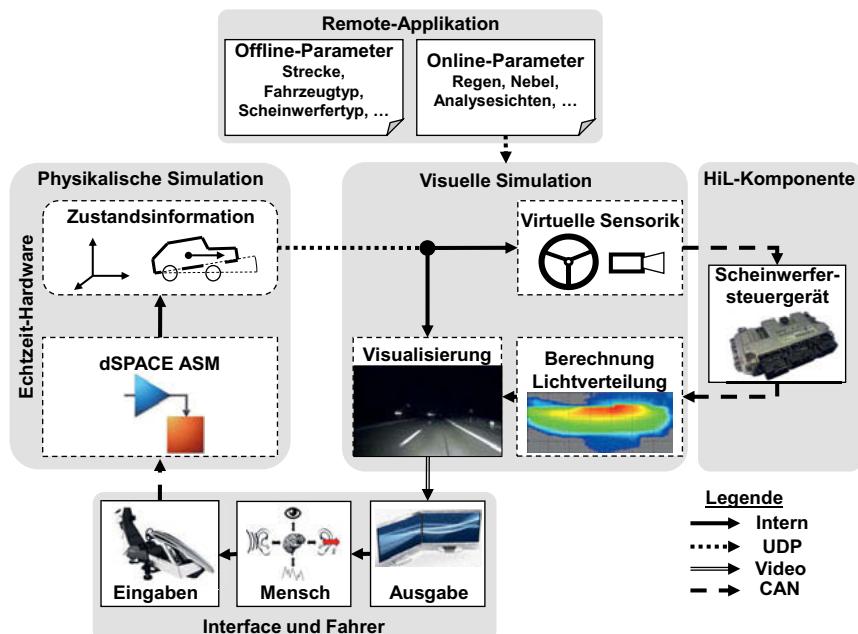


Abbildung 1: Hardware- und Software-Architektur der HiL-Simulation von HD-Scheinwerfersystemen im Fahrsimulator

#### Physikalische Simulation

Für die physikalische Simulation wird vollständig auf Produkte der dSPACE GmbH zurückgegriffen. Durch die Verwendung des komplexen Vollfahrzeugmodells aus der Automotive Simulation Models (ASM)-Toolsuite kann das reale Fahrverhalten sehr genau nachgebildet werden. Relevante Parameter wie der Fahrzeugtyp, die Verkehrssituation und die Teststrecke können über die Software ModelDesk spezifiziert werden. Damit die im

OpenDRIVE-Standard spezifizierten Teststrecken eingesetzt werden können, müssen diese zuvor in ModelDesk importiert werden. Das Vollfahrzeugmodell und die Verkehrssituation werden auf der Echtzeit-Hardware fortlaufend berechnet. Dabei werden die zur Visualisierung relevanten Zustandsinformationen mit einer Frequenz von 60 Hz an die visuelle Simulation übertragen.

### **Virtuelle Sensorik**

Im Gegensatz zur realen Fahrt erhält das Scheinwerfer-Steuergerät im HiL-Betrieb keine Sensorinformationen über den Zustand des eigenen Fahrzeugs und die Fahrzeugumgebung. Diese stellen jedoch die Grundlage für die Auswahl der zum aktuellen Zeitpunkt geeigneten Lichtverteilungen beider Scheinwerfer dar. Um eine hohe Übereinstimmung von realer Fahrt und Simulation zu gewährleisten, gilt es die relevanten Sensoren zu simulieren. Tabelle 1 enthält eine Auflistung der vom Scheinwerfer-Steuergerät ausgewerteten Sensorsignale.

*Tabelle 1: Relevante Sensorwerte für das Scheinwerfer-Steuergerät*

Sensorsignal	Messgröße	Einheit
$v_{VL}$	Translatorische Radumfangsgeschwindigkeit (vorne links)	km/h
$v_{VR}$	Translatorische Radumfangsgeschwindigkeit (vorne rechts)	km/h
$\dot{\psi}$	Gierrate	rad/s
$s_z$	Zahnstangenposition des Lenkgetriebes	m
Lichtsensor	Fahrzeug in dunkler Umgebung? (Wahr/Falsch)	-
Umfeldkamera	Diverse Informationen (gesonderte Diskussion)	

Der wichtigste und komplexeste Sensor des Scheinwerfersteuergeräts ist die Fahrzeug-Umfeldkamera. Sie erfasst die momentane Umgebungssituation vor dem Fahrzeug. Dazu gehören insbesondere die anderen Verkehrsteilnehmer. Die Umfeldkamera ist in der Lage, bis zu acht einzelne Objekte gleichzeitig zu erkennen. Für jedes Objekt hält sie die in Tabelle 2 aufgeführten Daten vor.

*Tabelle 2: Objektinformation der Objektliste der Fahrzeugumfeld-Kamera*

Name	Bedeutung	Wertebereich
ID	Jedes erkannte Objekt erhält eine ID	{0, 127}
Typ	Art des erkannten Objekts	Nicht erkannt, Scheinwerfer, Rückleuchte, Scheinwerferpaar, Rückleuchtenpaar, ...
$\theta$	Horizontale Position der Objektmitte im Kamerakoordinatensystem (KKS)	[-25,5°; +25,5°] (0° $\triangleq$ Fahrzeulgängsachse)
$\varphi$	Vertikale Position der Objektunterkante im KKS	[-1,0°; 7,0°] (0° $\triangleq$ Fahrzeulgängsachse)
$\Delta\theta$	Horizontale Dimension (Ausdehnung bzgl. Winkelbereich) des Objekts	[0,0°; 10,0°]

Die Informationen über die erkannten Objekte sind unabdingbar für das blendfreie Fernlicht (GFHB = Glare Free High Beam), in welcher die Windschutzscheiben entgegenkommender Fahrzeuge ausgeblendet werden. Die LED-Matrix verfügt dabei über eine derart hohe

Auflösung, dass mehrere blendungskritische Bereiche abgedimmt werden können, ohne den Lichteintrag im übrigen Bereich zu reduzieren. Neben der Objektliste unterstützt die Umfeldkamera eine Ortserkennung. Das Scheinwerfersystem schaltet im Bedarfsfall auf ein breiteres und weniger weitläufiges Stadtlicht um.

Während einfache Sensorsignale, wie Lenk- und Gierwinkel oder die Radgeschwindigkeiten, direkt vom Fahrzeugmodell auf der Echtzeit-Hardware abgegriffen werden können, muss die Funktionsweise der Umfeldkamera algorithmisch nachgebildet werden. Da nur die Visualisierung über die vollständigen Umfeldinformationen verfügt, wird die Kamera innerhalb dieser simuliert. Die Visualisierung überträgt die Kamerainformationen und die übrigen Sensorsignale, welche sie im Vorhinein via UDP vom Echtzeit-System erhalten hat, über eine eigene CAN-Schnittstelle an das Scheinwerfer-Steuergerät.

### **Scheinwerfer-Steuergerät**

Das Scheinwerfer-Steuergerät stellt die Testhardware in der HiL-Simulation dar. Die steuergeräteinternen Prozesse sind hier nicht Gegenstand der Betrachtung, daher beschränkt sich die Einbindung des Steuergerätes in die Gesamtarchitektur auf die Generierung der benötigten Eingangssignale und die Verarbeitung der Ausgangssignale. Erstere sind die Sensorwerte und wurden bereits im vorhergehenden Abschnitt diskutiert. Die Bestromungswerte der 168 LEDs (84 LEDs pro Matrix) beider Scheinwerfer mit je 6 Bit Auflösung stellen die Ausgangssignale dar. Da das Steuergerät mit einer Taktrate von 50 Hz operiert, müssen auch die Ein- und Ausgangssignale innerhalb von 20 ms erzeugt bzw. verarbeitet werden. Die auf dem Steuergerät berechneten Bestromungswerte beeinflussen lediglich die Visualisierung unmittelbar, weshalb keine Schnittstelle zwischen Steuergerät und physikalischer Simulation existiert.

### **Visualisierung**

Im Rahmen der Simulation wird die Visualisierung zur Nachbildung der durch das Auge wahrgenommenen Umgebung benötigt. Sie spielt deshalb bei der Simulation von Scheinwerfer-Systemen die zentrale Rolle. Nur durch sie gewinnt der Fahrer bzw. Entwickler einen Eindruck des durch die Scheinwerfer ausgesandten Lichts.

Grundsätzlich können die zu visualisierenden Elemente in verschiedene Gruppen eingeteilt werden – statische und dynamische Szenenobjekte, statische und dynamische Lichtquellen und Analyse-Ansichten. Unter statischen Szenenobjekten sind dabei alle Teile der Szene zu verstehen, die auch in realen Umgebungen beobachtet werden können, aber keiner Dynamik unterliegen. Zu dieser Gruppe zählen z. B. alle Objekte, die sich aus der Streckendefinition ergeben (Straßen, Leitpfosten, Bäume, Straßenlaternen, ...). Dynamische Szenenobjekte haben ebenfalls einen realen Ursprung, bewegen sich aber während der Simulation. Beispiele hierfür sind das Ego-Fahrzeug und der Fremdverkehr. Analog dazu haben statische Lichter, wie die Straßenbeleuchtung, eine gleichbleibende Position und Abstrahlcharakteristik, während die zu simulierenden HD-Scheinwerfer gemeinsam mit dem Fahrzeug sowohl ihre Positionen ändern, als auch abhängig von den Steuergerätausgaben ihre Abstrahlcharakteristik hochdynamisch anpassen. Sie können deshalb als dynamische

Lichtquellen verstanden werden. Zur letzten Gruppe zählen Analysewerkzeuge, welche den Ingenieur bei der Entwicklung und Erprobung des Scheinwerfersystems unterstützen. Es handelt sich hier beispielsweise um Falschfarben- oder Isolinien-Darstellungen.

Die Unterteilung in die genannten Gruppen gründet sich auf die unterschiedlichen Informationsflüsse, die zur Abbildung dieser Elemente in der Visualisierung erforderlich sind. Alle statischen Objekte können im Rahmen eines Pre-Processings einmalig für die jeweilige OpenDRIVE-Streckendefinition generiert werden und stehen anschließend für Simulationen zur Verfügung. Dynamische Objekte erfordern hingegen eine Anpassung in jedem Frame. Ihre Positionen werden gemeinsam mit den aus dem Fahrzeugmodell gewonnenen Sensorwerten via UDP von der physikalischen an die visuelle Simulation übertragen. Die Status-Nachricht weist dabei eine Struktur gemäß der Tabelle 3 auf.

Tabelle 3: Struktur einer UDP-Status-Nachricht

Datum	Bedeutung	Wertebereich
$e_{pos}$	xyz-Position des Ego-Fahrzeugs in Weltkoordinaten	$\mathbb{R}^3$
$e_{rot}$	Kardanwinkel des Ego-Fahrzeugs in Weltkoordinaten	$\mathbb{R}^3$
$b$	Existenz der Fremdfahrzeuge (max. 15 Fahrzeuge)	$\{0,1\}^{15}$
$F_{pos}$	xyz-Positionen der Fremdfahrzeuge in Weltkoordinaten	$\mathbb{R}^{3 \times 15}$
$F_{rot}$	Kardanwinkel der Fremdfahrzeuge in Weltkoordinaten	$\mathbb{R}^{3 \times 15}$
$v_{VL}$	Translatorische Radgeschwindigkeit (vorne links)	$\mathbb{R}$
$v_{VR}$	Translatorische Radgeschwindigkeit (vorne rechts)	$\mathbb{R}$
$\delta$	Lenkwinkel des Ego-Fahrzeugs	$\mathbb{R}$
$\psi$	Gierrate des Ego-Fahrzeugs	$\mathbb{R}$

Mit der Position  $e_{pos}$  und der Orientierung  $e_{rot}$  erfolgt die Positionierung des Ego-Fahrzeugs im Weltkoordinatensystem. Die ASM-Toolsuite der dSPACE GmbH unterstützt die gleichzeitige Simulation von maximal 15 Fremdfahrzeugen. Dementsprechend benötigt die visuelle Simulation zuerst eine Information darüber, wie viele Fremdfahrzeuge derzeit simuliert werden. Diese Information wird in einer 15-elementigen Bitfolge  $b$  abgebildet, wobei das Bit  $b(i)$  an der  $i$ -ten Stelle von  $b$  die Existenz des jeweiligen Fremdfahrzeugs definiert. Im Anschluss folgen analog zum Ego-Fahrzeug die translatorischen und rotatorischen Positionen aller Fremdfahrzeuge. Für  $b(i) = 0$  werden die  $i$ -ten Spalten der Matrizen  $F_{pos}$  und  $F_{rot}$  ignoriert. Die übrigen Daten entsprechen den bereits beschriebenen Sensorwerten.

Die visuelle Simulation berechnet auf Basis der Status-Nachricht und der vollständig bekannten dreidimensionalen Umgebung das Ausgabeverhalten der virtualisierten Umfeldkamera. Schließlich überträgt sie die Ausgaben der virtuellen Kamera und die übrigen Sensorwerte in Form steuergerätespezifischer CAN-Nachrichten an das Scheinwerfer-Steuergerät. Dieses berechnet die Lichtverteilung und schickt diese ebenfalls durch CAN-Nachrichten an die Visualisierung zurück. Hierbei handelt es sich um insgesamt 168 normierte Bestromungswerte der LED-Matrizen des linken und rechten Scheinwerfers.

### Echtzeit-Lichtberechnung

Auf Basis der Bestromungswerte aller LEDs müssen die Lichtstärkeverteilungen beider Scheinwerfer mit der Taktfrequenz des Scheinwerfer-Steuergeräts von 50 Hz bestimmt werden. Ein Verfahren zur shader-basierten Berechnung dieser Informationen in Echtzeit wurde bereits veröffentlicht und soll hier nur schematisch diskutiert werden [13]. Als Datengrundlage liegen Lichtstärkeverteilungen bei maximaler Bestromung für jede einzelne der insgesamt 168 Lichtquellen vor. Abbildung 2 zeigt beispielhaft die Lichtstärkeverteilung der LED 1 der linken Matrix.

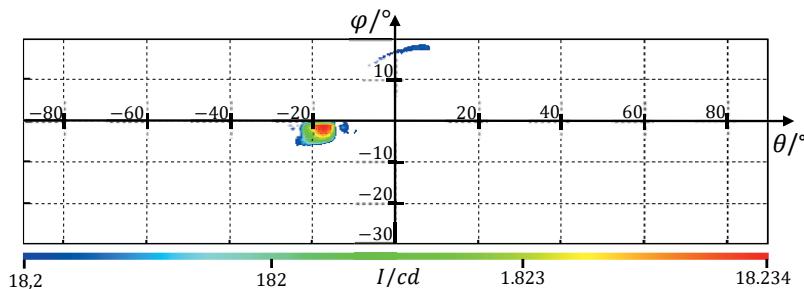


Abbildung 2: Lichtstärkeverteilung der LED 1 der HD84-Matrix des linken Scheinwerfers.

In ihr ist die Lichtstärke  $I$  des Scheinwerfers abhängig vom Polarwinkel  $\varphi$  (vertikal) und Azimutwinkel  $\theta$  (horizontal) logarithmisch in Falschfarben dargestellt.  $\varphi = \theta = 0^\circ$  entspricht der Richtung parallel zur Fahrzeulglängsachse ausgehend von der Scheinwerfereinbauposition. Überlagert man die Lichtstärkeverteilungen aller LEDs der Matrix gewichtet mit ihren momentanen relativen Bestromungen, so ergibt sich die Lichtstärkeverteilung des Scheinwerfers. Die Ausleuchtungsbereiche der einzelnen LEDs sind dabei weitestgehend voneinander separiert und erlauben ein bausteinartiges Zusammensetzen der Gesamtlichtverteilung. Hochdynamisches Anpassen der Bestromungswerte ermöglicht in jeder Fahrsituation eine adäquate Lichtverteilung. Abbildung 3 visualisiert beispielhaft eine auf diese Weise entstehende Abblendlichtverteilung.

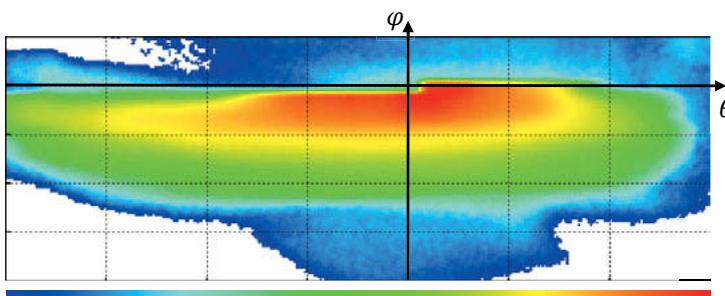


Abbildung 3: Abblendlichtverteilung des linken Scheinwerfers.

Die sich ergebenden Gesamtlichtstärkeverteilungen beider Scheinwerfer können dann durch einen weiteren Shader zur Beleuchtung der Szene verwendet werden. Diese Implementierung wurde in [13] vorgestellt und validiert.

## **Fahrer**

Der menschliche Fahrer kann ebenfalls als Komponente der Gesamtsimulation verstanden werden. Insbesondere im Kontext visueller Assistenzsysteme, welche nicht unmittelbar in die Fahrzeugaktorik eingreifen, kommt seiner optischen Wahrnehmung eine wesentliche Bedeutung zu. Durch die Fahreingaben, die zum Großteil von visuellen Reizen bestimmt werden, werden Ausgaben des Steuergeräts in das Fahrzeugmodell mittelbar rückgekoppelt, wodurch der Fahrer den Regelkreis schließt. Sein subjektiver Eindruck ist darüber hinaus das maßgebliche Bewertungskriterium des Scheinwerferlichts, da im Falle der Gestaltung von Lichtverteilungen die individuellen Präferenzen und Designaspekte bei der Kaufentscheidung der Automobilhersteller deutlich stärker gewichtet werden als objektive Gütemaße.

## **4. Parametrierung und Steuerung**

Mit der Parametrierung werden alle Eigenschaften der durchzuführenden Simulation festgelegt. Der Parameterraum ist vielfältig und wird hier nur in Ansätzen beschrieben. Grundsätzlich kann er aber in zwei Klassen aufgeteilt werden – Offline- und Online-Parameter. Als Offline-Parameter sind alle Parameter zu verstehen, deren Werte vor Beginn der Simulation definiert werden müssen und im weiteren Verlauf unverändert bleiben. Online-Parameter lassen sich hingegen während der Simulation anpassen. Zur externen Steuerung sind das Setzen der Offline- und Online-Parameter sowie die Fernsteuerung der Hardware-Komponenten in eine gesonderte Applikation ausgelagert, welche via UDP mit der Visualisierung verbunden werden kann. Auf diese Weise wird eine flexible und benutzerfreundliche Bedienung der Simulation ermöglicht.

### **Offline-Parametrierung**

Vor dem Simulationsbeginn sind abhängig von den zu testenden Lichtfunktionen unterschiedliche Entscheidungen zu treffen. Neben dem zu testenden Scheinwerfertyp ist zum Beispiel die virtuelle Szene ein zentrales Auswahlkriterium. Bei ihrer Wahl muss der Testingenieur verschiedene Aspekte berücksichtigen. So setzt beispielsweise die Erprobung einer Kurvenlicht-Funktion einen kurvigen Streckenverlauf voraus. Außerdem muss das Testfahrzeug definiert werden. Dieses bestimmt neben der Einbaulage der Scheinwerfer auch das dynamische Verhalten des Fahrzeugaufbaus und damit die Relativbewegung der Scheinwerfer zur Fahrbahnebene. Nach Festlegung aller Offline-Parameter kann die Simulation gestartet werden.

### **Online-Parametrierung**

Während der Simulation kann abgesehen von den Fahreingaben ausschließlich durch die Online-Parameter Einfluss genommen werden. Diese können inhaltlich in drei Gruppen unterteilt werden – Lichtberechnung, Umgebungsbedingungen und Lichtanalyse. Die Gruppe „Lichtberechnung“ beinhaltet alle Parameter, welche Einfluss auf die Berechnung der Pixelfarben unter Berücksichtigung des Scheinwerferlichts nehmen. In Tabelle 4 findet sich eine Auflistung aller Parameter dieser Gruppe.

Tabelle 4: Online-Parameter „Lichtberechnung“

Name	Bedeutung	Wertebereich
Beleuchtungsmodell	Art des zu verwendenden Beleuchtungsmodells	{Phong-Blinn, UnityPBS}
Abschwächung	Distanzabhängige Abschwächung der Lichtstärke	{stetig + stückw. linear, quadratisch-reziprok}
Grundverstärkung	Winkelunabh. Skalierungsfaktor der Lichtstärke	$\mathbb{R}^{>0}$
Reichweite	Max. Reichweite eines Lichtstrahls	$\mathbb{R}^{>0}$

Durch den Parameter „Beleuchtungsmodell“ wird festgelegt, durch welches lokale Beleuchtungsmodell die Pixelfarben ermittelt werden. Neben dem internen Beleuchtungsmodell „Physically-Based Shading“ (PBS) der für die Visualisierung verwendeten Entwicklungsumgebung „Unity3D“ kann auch ein einfaches Phong-Blinn-Modell verwendet werden. Unabhängig vom verwendeten Beleuchtungsmodell kann die distanzabhängige Abschwächung des Lichts variiert werden. Neben der physikalisch korrekten quadratisch-reziproken Abschwächung können auch andere Varianten implementiert werden. Bedingt durch den begrenzten Kontrast der Ausgabegeräte, können diese durch leichtes Abweichen vom streng physikalischen Zusammenhang bessere Ergebnisse erzielen. Die Grundverstärkung kann als Kalibrierwert der generellen Scheinwerferhelligkeit verstanden werden. Mit ihr wird die gesamte Lichtstärkeverteilung unabhängig vom Raumwinkel multipliziert. Sie ist so zu wählen, dass der Helligkeitseindruck einer realen Szene und deren virtuellem Abbild bei gleicher Lichtverteilung möglichst gut übereinstimmen. Die Reichweite einer Lichtquelle legt fest, in welchem geometrischen Volumen ein Einfluss der Lichtquelle potentiell möglich ist. Näheres hierzu kann unter dem Begriff „Light Volume“ in [13] nachgeschlagen werden. Dieser Parameter dient primär der Performance-Optimierung.

Die zweite Gruppe der Online-Parameter stellen die Umgebungsbedingungen dar. Sie sind in Tabelle 5 zusammengefasst. Sowohl bei Tag- als auch Nachtfahrten können Regen und Nebel simuliert werden. Bei der Aktivierung von Regen werden einerseits durch einen Partikeleffekt der Eindruck von Wassertropfen in der Luft erzeugt und andererseits das Reflexionsverhalten der Straße angepasst. Nebel wird durch eine distanzabhängige Abschwächung der Sicht realisiert. Hierzu wird die Pixelfarbe ohne Nebelleffekte mit einer definierbaren Nebelfarbe (i.d.R. Graustufe) vermischt. Die Anteile der Farben werden dabei distanzabhängig verändert, wobei zwischen drei verschiedenen Distanzfunktionen gewählt werden kann.

Tabelle 5: Online-Parameter „Umgebungsbedingungen“

Name	Bedeutung	Wertebereich
Tag/Nacht-Modus	Wahl zwischen Tag- und Nachtfahrt	{Wahr, Falsch}
Regen-Flag	Visualisierung von Regen-Effekten	{Wahr, Falsch}
Regenstärke	Skalierung der Regen-Effekte	[0, 1]
Nebelmodus	Distanzfunktion zur Sichtabschwächung	{Linear, Exp, ExpSquared}
Nebeldichte	Skalierung der Nebel-Effekte	[0, 1]

In Tabelle 6 sind die Parameter zur Lichtanalyse aufgelistet. Auf Wunsch kann eine im Fahrzeugkoordinatensystem fixierte Messwand eingeblendet werden. Auf ihr befinden sich horizontale und vertikale Kontrolllinien. Eine solche Messwand ist ein etabliertes Bewertungsinstrument für Scheinwerferlicht. Sie fängt die Projektion des Lichts in der vertikalen Ebene auf und erfasst somit dessen Gestalt wesentlich kompakter als auf der Straße. Die Power-Matrix-Sicht visualisiert in Echtzeit die Bestromungswerte aller LEDs der Matrizen und die resultierenden Lichtstärkeverteilungen der Einzelscheinwerfer.

Tabelle 6: Online-Parameter „Lichtanalyse“

Name	Bedeutung	Wertebereich
Messwand	Weiße Wand mit roten Kontrolllinien im Abstand von 10m vor den Scheinwerfern	{Wahr, Falsch}
Power-Matrix-Sicht	Echtzeitgrafik der Bestromungen aller LEDs und den Gesamtlichtstärkeverteilungen des linken u. rechten Scheinwerfers	{Wahr, Falsch}
Lichttechnische Größe	Auswahl der lichttechnischen Größen	{Beleuchtungsstärke, Leuchtdichte}
Visualisierungstyp	Visualisierung der lichttechnischen Größe	{Iso-Linien, Falsch-Farben}
Skalierung	Skalierung der lichttechnische Größe	{Linear, Log10}

Die übrigen drei Parameter sind gebündelt zu betrachten. Sie erlauben das Hervorheben von verschiedenen lichttechnischen Größen durch unterschiedliche Visualisierungstypen. Als zu visualisierende Lichtgröße kann entweder die Beleuchtungsstärke oder die Leuchtdichte ausgewertet werden.

## 5. Simulationsergebnisse

Während der Simulation berechnet die Visualisierung wiederkehrend die momentane Gestalt der Szene (Frame). In diesem Abschnitt sollen die Ergebnisse der HD-Scheinwerfer-Simulation anhand einiger Bildausschnitte gezeigt und näher erläutert werden.

### Blendfreies Fernlicht

Abbildung 4 zeigt eine Momentaufnahme der Visualisierung. Das Ego-Fahrzeug wird im aktuellen Setup nicht gerendert, da es im Fahrsimulator als reales Mockup existiert. Das Rendering erfolgt auf der verwendeten Simulationshardware (Windows 10 Pro 64bit, Intel i7-6820HQ, GeForce GTX TI 1080, 16GB RAM) mit 60 Frames pro Sekunde und schöpft somit die Bildwiederholfrequenz herkömmlicher Bildausgabegeräte vollständig aus.

Die Power-Matrix-Sicht ist aktiv. An der unteren linken bzw. rechten Ecke werden die Bestromungswerte der je 84 LEDs des linken bzw. rechten Scheinwerfers angezeigt. Jedes farbige Kästchen entspricht dabei einer LED und die darin befindliche Zahl der ID dieser LED. Die Anordnung der Kästchen korrespondiert mit der physikalischen Einbaurlage in der Matrix. Die momentan vorliegende Bestromung jeder LED wird durch Falschfarben codiert (rot:  $i = i_{max}$ , blau:  $i = 0$ ). An den oberen Ecken werden die aus den Bestromungen resultierenden Lichtstärkeverteilungen beider Scheinwerfer eingeblendet.

Den größten Gewinn gegenüber klassischen Scheinwerfersystemen entfalten HD-Systeme durch die hochflexible Anpassung an die vorliegende Umfeldsituation. Der Fremdverkehr stellt dabei den wesentlichen Anteil dar und wird deshalb ebenfalls simuliert.

Wie insbesondere aus der Power-Matrix-Sicht hervorgeht, wird das entgegenkommende Fahrzeug durch das Abdimmung geeigneter LEDs gezielt entblendet. Erkannt wird dieses durch die virtuelle Umfeldkamera. Auf diese Weise wird das Ein-/Ausgangsverhalten des Steuergeräts für den Entwickler transparent dargelegt. Er kann darauf basierend Rückschlüsse zur weiteren Optimierung des auszulegenden Lichtsteueralgorithmus ableiten.

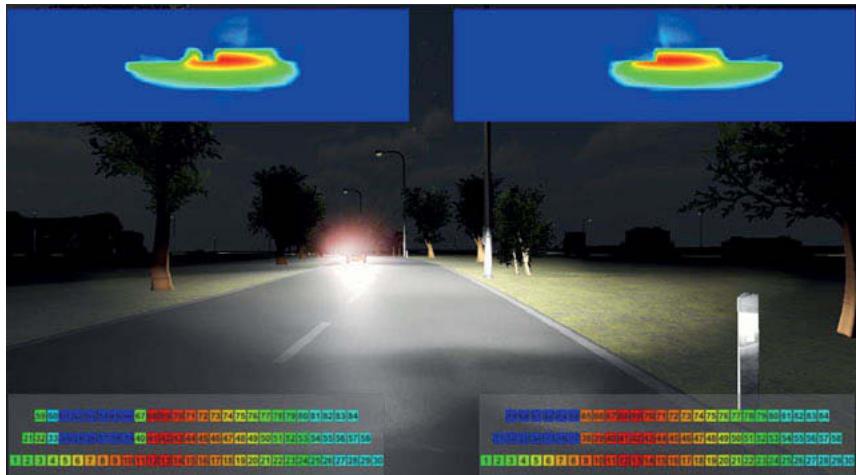


Abbildung 4: Screenshot der Visualisierung bei entgegenkommendem Fremdverkehr. Einige LEDs des linken und rechten Scheinwerfers werden gedimmt, um den Verkehrsteilnehmer nicht zu blenden.

### Wetterbedingungen

Die schnelle Definition und Reproduzierbarkeit verschiedener Fahrszenarien sind wesentliche Vorteile der simulationsgestützten Entwicklung. Hierzu zählen im Anwendungsfall vor allem die Wetterverhältnisse, die in realen Nachtfahrten nicht beherrschbar sind.

Beispielhaft zeigt Abbildung 5 die Nachtfahrt bei Regen. Im Vergleich zu einer Fahrt bei trockenem Wetter (siehe Abbildung 4) sind deutliche Unterschiede erkennbar. Die wahrgenommene Helligkeit der Fahrbahn durch das eigene Scheinwerferlicht nimmt ab, da ein größerer Anteil in die Ferne reflektiert wird. Gleichzeitig sorgen die spiegelnden Eigenschaften einer nassen Fahrbahn für besonders helle Reflexionsstreifen in Richtung der Scheinwerfer anderer Verkehrsteilnehmer. Die Struktur der Fahrbahn kommt ebenfalls deutlicher heraus. Durch derartige Simulationen kann eine Einschätzung der Wettereinflüsse auf das Verhalten des Fahrers gewonnen werden.



Abbildung 5: Screenshot der Visualisierung bei Regenfahrt. Der Straßenbelag spiegelt.

## 6. Fazit und Ausblick

Der vorgestellte Gesamtaufbau eines HiL-Fahrstudiulators setzt die Simulation von hochauflösenden Scheinwerfersystemen erstmalig in Echtzeit um und ermöglicht somit die Entwicklung von dynamischen Lichtfunktionen durch virtuelle Nachtfahrten. Als signifikante Vorteile gegenüber den bisher notwendigen realen Nachtfahrten sind die Unabhängigkeit von der Tageszeit und den Wetterbedingungen, die vollständige Reproduzierbarkeit und die schnelle Generierung und Durchführung verschiedener Testszenarien zu nennen.

In zukünftigen Arbeiten soll zum einen die Scheinwerfer-Simulation auf Lichtverteilungen mit spektralen Informationen erweitert werden. Die an der Hell-Dunkel-Grenze auftretenden Farbverläufe von LEDs gewinnen im Kontext der neuen Scheinwerfersysteme an Relevanz. Zum anderen ist die Integration zusätzlicher Analysemöglichkeiten Gegenstand derzeitiger Arbeiten. Hierbei stehen die zugängliche Visualisierung photometrischer Größen und ihre intuitive Anpassung zur gezielten Optimierung der Lichtsteueralgorithmen im Vordergrund.

## Literatur

- [1] "AutomobilIndustrie: Adaptives LCD-Licht mit 30.000 Pixeln," 2017, URL: [www.automobilindustrie.vogel.de/index.cfm?pid=1&pk=629502&p=1](http://www.automobilindustrie.vogel.de/index.cfm?pid=1&pk=629502&p=1) [Zugriff: 8, 2018].
- [2] B. Fleury, L. Evrard, J.-P. Ravier, and B. Reiss, "Expanded Functionality of Glare Free High Beam Systems," ATZ Autotechnology, 2012.
- [3] M. Enders, "Pixel light," Progress in Automobile Lighting (PAL), 2001.
- [4] F.-J. Kalzki and D. Brunne, "LED im Fahrzeug: Die Rolle der Matrixscheinwerfer und was sie leisten," Elektronik Praxis, 2018.
- [5] C. Schmidt, B. Willeke, and B. Fischer, "Laser versus Hochleistungs-LED - Vergleich der Einsatzmöglichkeiten bei hochauflösenden Matrix-Scheinwerfer-Systemen," VDI-Tagung Optische Technologien in der Fahrzeugtechnik, Karlsruhe, 2016.
- [6] P. Lecocq, J.-M. Kelada, and A. Kemeny, "Interactive Headlight Simulation," Driving Simulation Conference, 1999.
- [7] J. Berssenbrügge, J. Gausemeier, M. Grafe, C. Matysczok, and K. Pöhlund, "Real-Time Representation of Complex Lighting Data in a Nightdrive Simulation," 9. Eurographics Workshop on Virtual Environments, 2003.
- [8] J. Löwenau and M. Strobl, "Advanced Lighting Simulation (ALS) for the Evaluation of the BMW System Adaptive Light Control (ALC)," International Body Engineering Conference & Exhibition, Automotive & Transportation Technology Conference, 2002.
- [9] A. Kemeny et al., "Application of real-time lighting simulation for intelligent front-lighting studies," Driving Simulation Conference, 2000.
- [10] J. Berssenbrügge, J. Bauch, and J. Gausemeier, "A Virtual Reality-based Night Drive Simulator for the Evaluation of a Predictive Advanced Front Lighting System," Design Engineering Technical Conferences & Computers and Information in Engineering Conference, 2006.
- [11] J. Berssenbrügge, S. Kraft, and J. Gausemeier, "Virtual Prototyping of an Advanced Leveling Light System Using a Virtual Reality-Based Night Drive Simulator," Journal of Computing and Information Science in Engineering, 2010.
- [12] A. Knoll et al., "Evaluation of an Active Safety Light using Virtual Test Drive within Vehicle In The Loop," IEEE International Conference on Industrial Technology, 2010.
- [13] N. Rüddenklau, P. Biemelt, S. Henning, S. Gausemeier, and A. Trächtler, "Shader-based realtime simulation of high-definition automotive headlamps," IARIA SIMUL 2018, The Tenth International Conference on Advances in System Simulation, 2018.

# Full Speed Range Adaptive Cruise Control

## Anforderungen und Herausforderungen in der Praxis

Dr.-Ing. **Radoy Stanchev**,

Continental Engineering Services GmbH, Frankfurt a. M.;

Dr.-Ing. **Fabian Becker**,

Continental Teves AG & Co. oHG, Frankfurt a. M.

### Zusammenfassung

Dieser Beitrag stellt ausgewählte Aspekte der Entwicklung einer ACC Funktion für Serienanwendungen vor und legt den Fokus auf die Planung komfortabler Trajektorien für Full Speed Range Anwendungen. Dabei wird unter Berücksichtigung von Beschleunigungs-limitierungen ein modularer Ansatz zur Planung von mehrteiligen Trajektorien basierend auf Online-Optimierung diskutiert. Weiterhin wird die Kombination der optimalen Trajektorien-planung mit einer virtuellen Stoßstange sowie einem Ansatz zur Vorgabe stetiger und konsistenter Zielobjektzustände vorgeschlagen, um in der Praxis vor allem in Stop-And-Go Szenarien auftretende Herausforderungen zu adressieren.

### 1. Motivation

Auf dem Weg zum vollautomatisierten Fahren stellt Adaptive Cruise Control (ACC) eine wichtige Basisfunktionalität dar. ACC wird seit etwa 20 Jahren kommerziell angeboten, jedoch betrachten und analysieren die meisten Veröffentlichungen zu diesem Thema lediglich das grundsätzliche Verhalten in isolierten Anwendungsszenarien, ohne dabei die Gesamtheit der ACC Entwicklung für Serienanwendungen darzulegen. Dieser Beitrag fokussiert sich daher auf relevante Fragestellungen, die bei der Entwicklung und der Implementierung von ACC für Serienanwendungen auftreten.

Zunächst werden in Abschnitt 2 die Anforderungen an ein heutiges ACC Regelungskonzept diskutiert. Basierend darauf wird in Abschnitt 3 ein geeignetes Regelungskonzept gewählt und in Abschnitt 4 eine mögliche Systemarchitektur vorgestellt. Abschnitte 5, 6 und 7 widmen sich Fragestellungen, die bei der Implementierung der Full Speed Range ACC Funktion in der Praxis auftreten. Im Speziellen umfasst dies die Ausnutzung von Stellgrößenbeschränkungen und Erzeugung von geeigneten Sollwerten für den Regelkreis, das Bremsen in und Anfahren

aus dem Stillstand sowie die Optimierung des Regelungskonzeptes in Bezug auf Robustheit und Ressourcenbedarf. Der Beitrag schließt mit einem kurzen Ausblick in Abschnitt 8.

## 2. Anforderungen an ein Fahrerassistenzsystem

Die Entwicklung eines Fahrerassistenzsystems muss diverse kundenspezifische, gesellschaftliche und auch entwicklungsspezifische Anforderungen berücksichtigen. Aspekte der Entwicklung sind nicht zwangsläufig sichtbar für den Endbenutzer, jedoch sind sie wichtig für das Passieren interner Qualitätssicherungsprozesse oder für die interne Akzeptanz eines gewählten Lösungsansatzes. Entsprechend ist die gute Verständlichkeit des verwendeten Regelungsansatzes in der industriellen Praxis wichtig, um die Vielzahl der beteiligten Entwickler, mit teilweise nur grundlegenden Regelungstechnischen Kenntnissen, einfach abholen und in die (Weiter-) Entwicklung einbinden zu können.

In Hinblick auf die gewünschte Applikation eines Fahrerassistenzsystems in verschiedenen Fahrzeugplattformen ist weiterhin eine einfache und intuitive Parametrierung wichtig. Die Parameter sollen auf eine transparente und intuitive Weise das Systemverhalten beeinflussen. Dabei sollen einerseits spezifische Änderungen des Systemverhaltens möglich sein (z.B. für den Verlauf des Beschleunigungsaufbaus), andererseits soll auch eine globale Änderung des Gesamtverhaltens möglich sein (z.B. für den Wechsel zwischen Fahrmodi), ohne dabei alle Parameter von Anfang an ändern zu müssen.

Zur Steigerung der Kundenakzeptanz wird die ACC Basisfunktion in heutigen Systemen häufig um Zusatzfunktionen wie prädiktives Bremsen vor Kurven oder automatisches Beschleunigen zur Unterstützung eines fahrerinitiierten Überholvorgangs erweitert. Weiterhin steigen die Ansprüche an die Güte des Regelverhaltens bzgl. Komfort und Dynamik stetig. Damit das entwickelte Fahrerassistenzsystem nicht nur die aktuellen Anforderungen erfüllt, sondern die Marktanforderungen langfristig bedienen kann, ist eine gute Skalierbarkeit des gewählten Regelungsansatzes in Bezug auf Funktionsumfang, Funktionsperformance und Ressourcenbedarf auf dem Steuergerät wichtig.

Eine hohe Akzeptanz bei Endbenutzern erzielt eine ACC Funktion durch komfortables und vorhersehbares Verhalten. Das menschliche Komfortempfinden korreliert stark mit den aktuellen Werten der Beschleunigung und des Rucks, sodass deren Begrenzung im ACC Regelungskonzept wichtig ist. Gleichzeitig sollte das System dem Fahrer und anderen Insassen Feedback zum aktuellen Betriebszustand und aufkommenden Systemgrenzen deutlich und reproduzierbar vermitteln, um Vertrauen in die Fähigkeiten des Systems aufzubauen bzw. zu

erhalten. Zum Beispiel kann das Einleiten einer Bremsung bei der Zufahrt auf ein langsameres Fahrzeug, und damit der Wechsel von Geschwindigkeits- auf Abstandsregelung, mit einem geringen aber spürbaren Ruck signalisiert werden.

Wird die ACC Funktion ausschließlich mit Blick auf den Insassenkomfort ausgelegt, kann es passieren, dass das resultierende Fahrzeugverhalten den Verkehrsfluss stört. Zwar können solche Störungen von den restlichen Verkehrsteilnehmern ausgeglichen werden, so lange vergleichsweise wenige Fahrzeuge mit ACC ausgestattet sind (5% im Jahr 2017 [1]), in Hinblick auf das vollautomatisierte Fahren wird jedoch die Relevanz volkswirtschaftlicher Aspekte, wie der Erhöhung der Verkehrsflussdichte, steigen. Zukünftig sind diesbezüglich auch gesetzliche Empfehlungen bzw. Vorgaben nicht auszuschließen [2].

### 3. Wahl des Regelungskonzeptes

Aufbauend auf den Anforderungen im vorherigen Abschnitt wird im Folgenden ein geeignetes Regelungskonzept für die Geschwindigkeits- und Abstandsregelung gewählt und anschließend in ein ACC Gesamtkonzept eingebettet. In Zusammenhang mit ACC Funktionen sind lineare und nichtlineare analytische Regler sowie auf Fuzzy Logic, neuronalen Netzen und Online-Optimierung basierende Regler denkbar. Tabelle 1 vergleicht diese Regelungsansätze qualitativ anhand ausgewählter Kriterien und verweist auf Literaturangaben zu deren Verwendung in ACC Funktionen.

Lineare Regler und Fuzzy Logic sind sehr anschaulich, sodass die Vorgehensweise beim Reglerentwurf gut vermittelt werden kann. Die meist geringe Anzahl an Applikationsparametern linearer Regler ermöglicht zwar einen einfachen Reglerentwurf, schränkt in der Praxis jedoch die Freiheit beim Einstellen eines ACC-Wunschverhaltens ein. Die ACC Basisfunktion kann z.B. durch einen PD-Regler realisiert werden. Die Bestrebung lineare Regelungskonzepte besser parametrierbar und skalierbar zu machen, führt zu nichtlinearen Regelungskonzepten. Diese verschaffen u.a. durch situationsabhängige Parameteranpassungen mehr Freiheit in der Applikation, jedoch leidet darunter die Anschaulichkeit. Bspw. kann ein linearer Regler mit einem Fahrermodell erweitert werden. Bei den meisten Fahrermodellen handelt es sich um statistische Modelle, die durch nichtlineare Feder-Dämpfer-Systeme dargestellt werden können [3]. Analytische Regler haben meist einen niedrigen Ressourcenaufwand und können damit auch auf kostengünstigen Steuergeräten genutzt werden. Sie teilen sich mit den meisten anderen Regelungsansätzen jedoch die Problematik der schwierigen Berücksichtigung von Zustandsgrößenbeschränkungen.

Tabelle 1: Qualitativer Vergleich von Regelungsansätzen (⊕ positiv | ○ neutral | ⊖ negativ)

	Analytische Regler		Fuzzy Lo- gic	Neuronale Netze	Online Opti- mierung
	Linear	Nichtlinear			
Verständlichkeit	⊕	⊖ ... ○	⊕	⊖ ... ○	⊖ ... ○
Parametrierbarkeit	○	○ ... ⊕	⊖	⊖	○ ... ⊕
Skalierbarkeit	⊖	○	○	○	⊕
Ressourcenaufwand	⊕	⊕	⊕	⊖ ... ○	⊖ ... ○
Stellgrößen- und Zu- standsbeschränkungen	○	○	⊖	○	⊕
Literaturangaben	[4]	[5]	[6]	[7]	[8], [9]

Bei einem niedrigen Ressourcenaufwand bieten auf Fuzzy Logic basierende Regler die Möglichkeit an, das Systemverhalten in regelbasierter Form detailliert vorzugeben. Dieser Vorteil führt bei größeren Regelsätzen mit mehreren Eingangsvariablen jedoch schnell zu sehr großem Aufwand bei der Parametrierung, insbesondere dann, wenn es beim Reglerentwurf zu unbeabsichtigten Verkopplungen einzelner Regeln kommt. Es ist weiterhin schwierig, das globale Systemverhalten zu ändern, um bspw. unterschiedliche Fahrmodi (z.B. Komfort oder Sport) darzustellen. Oft muss hierfür eine Vielzahl an Regeln angepasst werden.

Neuronale Netze weisen vor allem den Nachteil der aufwendigen Parametrierung auf. Änderungen des Systemverhaltens sind im Allgemeinen mit einem erneuten Anlernen des neuronalen Netzes verbunden und erfordern entsprechende Lern- und Validierungsdaten. Dies schließt die schnelle Anpassung des Systemverhaltens durch einen Applikateur, z.B. während einer Testfahrt, aus. Unter Berücksichtigung der in Abschnitt 2 beschriebenen Anforderungen und des aktuellen Stands der Technik erscheinen neuronale Netze und Fuzzy Logic aufgrund ihrer eingeschränkten Skalierbarkeit und Parametrierbarkeit aus heutiger Sicht für die ACC Funktionalität ungeeignet.

Optimierungsalgorithmen können durchaus eine hohe theoretische Komplexität aufweisen, jedoch kann das Gütemaß eines Optimierungsproblems (und das ist die Schnittstelle zum Anwender) sehr anschaulich erklärt werden. Die tatsächliche Komplexität eines Optimierungsproblems hängt entscheidend von der Gestaltung des Gütemaßes ab: einfachere Gütemaße führen auf leicht und mit wenig Rechenaufwand zu lösende Optimierungsprobleme und umgekehrt. Ein verfügbares Mehr an Rechenleistung kann durch ein komplexeres Gütemaß (z.B. Aspekte der Fahrzeugquerbewegung) oder einen leistungsfähigeren Solver in eine höhere Regelgüte investiert werden.

Wird ausschließlich die ACC Basisfunktionalität betrachtet, so kommt die Kombination aus einem Fahrermodell und einem linearen oder nichtlinearen analytischen Regelungsansatz in Frage. Sollen jedoch weiterhin eine einfache Skalierbarkeit (Zukunftspotential), eine intuitive Parametrierbarkeit, Zustandsbeschränkungen und – mit Blick auf vollautomatisiertes Fahren – eine Kombination mit der Querdynamik berücksichtigt werden, so erscheinen auf Online-Optimierung basierende Regelungskonzepte eine vielversprechende Alternative zu sein. Das hier vorgestellte ACC Regelungskonzept besteht aus einer auf Online-Optimierung basierenden Trajektorienplanung und einem Folgeregler sowie in Anlehnung an [8] und [9] aus einer Strategie zur Reinitialisierung der Trajektorienplanung. In diesem Beitrag wird nur auf die Trajektorienplanung eingegangen.

Um den Ressourcenbedarf bei der Trajektorienberechnung zu reduzieren, wird wie in [8] und [9] das Optimierungsproblem approximativ gelöst. Hierfür wird in einem ersten Schritt das Gütemaß so aufgestellt, dass die optimale Trajektorie analytisch berechnet werden kann. In einem zweiten Schritt wird eine Schar aus Trajektorien berechnet und die beste Trajektorie daraus als Lösung des Optimierungsproblems gewählt. In diesem Schritt werden die Nebenbedingungen berücksichtigt, deren Vernachlässigung im ersten Schritt eine analytische Lösung des Optimierungsproblems erlaubt.

Für die Berechnung der Trajektorienschär werden Rasterpunkte im von der Endzeit und der Endposition bzw. Endgeschwindigkeit der Trajektorie aufgespannten Suchraum gewählt. Die Anzahl und die Verteilung der Rasterpunkte bestimmen, wie gut die exakte Lösung des Optimierungsproblems durch die berechnete Trajektorie approximiert wird. Eine feine Rasterung des Suchraums steht im Gegensatz zu einem niedrigen Rechenbedarf. In bestimmten Situationen ist es jedoch notwendig, sehr fein zu rastern, um eine gültige Lösung zu finden. Nachteilig an einer festen und groben Rasterung ist der nicht kontinuierliche Einfluss der Optimierungsparameter auf die gefundene Lösung. Das Tuning eines Applikationsparameters der Optimierung bewirkt solange keine Änderung der Trajektorie, bis ein anderer Rasterpunkt ein niedrigeres Gütemaß aufweist als der aktuelle Rasterpunkt. Dieses Verhalten erschwert die Applikation und verhindert ein intuitives Vorgehen in der Praxis. Daher wird in Abschnitt 7 ein adaptiver Suchraum vorgeschlagen.

Wichtig in der Praxis ist das näherungsweise Einhalten der zeitlichen Konsistenz der Trajektorienberechnung. Denn nur so kann ein gewünschtes und parametrisiertes Verhalten reproduzierbar erreicht und Vertrauen bei den Insassen in das Fahrerassistenzsystem aufgebaut wer-

den. Weiterhin lässt sich dadurch der Rechenaufwand reduzieren, da bei einer kleinen Änderung des Fahrzeugumfelds auch eine kleine Änderung in der gefundenen Trajektorie zu erwarten ist, d.h. die Wahl der Rasterpunkte im Suchraum kann angepasst werden.

#### 4. Struktur der Trajektorienplanung

Die in dieser Arbeit vorgeschlagene Trajektorienplanung teilt sich in eine Koordinations- und eine Planungsebene. Ihre Struktur ist in Bild 1 dargestellt. Während die Planungsebene Trajektorien zur Überführung des Fahrzeugs von einem Anfangszustand in einen gewünschten Zielzustand berechnet, stellt die Koordinationsebene eine Schnittstelle zur situations- und funktionspezifischen Parametrierung der einzelnen Planer zur Verfügung.

Aufgrund der grundlegend verschiedenen Optimierungsziele für eine Freifahrt ohne Zielobjekt (Geschwindigkeitsregelung) und eine Folgefahrt mit Zielobjekt (Abstandsregelung), besteht die Planungsebene aus einem Planer für Geschwindigkeitstrajektorien und einem oder mehreren (Multi-Objekt ACC) Planern für Wegtrajektorien. Für den Wechsel zwischen Trajektorien der Freifahrt und der Folgefahrt schließt an die unterschiedlichen Planer ein Modul zur Trajektorienselektion an. Eine Strategie zur Trajektorienselektion nach dem aktuellen Stand der Technik stellt die Minimumarbitrierung auf Basis der Beschleunigung im ersten Schritt der Trajektorien dar [10]. Alternativ können in der Trajektorienselektion die kompletten Trajektorien ausgewertet werden und die Umschaltung basierend auf weiteren Kriterien durchgeführt werden. Durch diesen Freiheitsgrad können z.B. Umweltaspekte berücksichtigt werden.

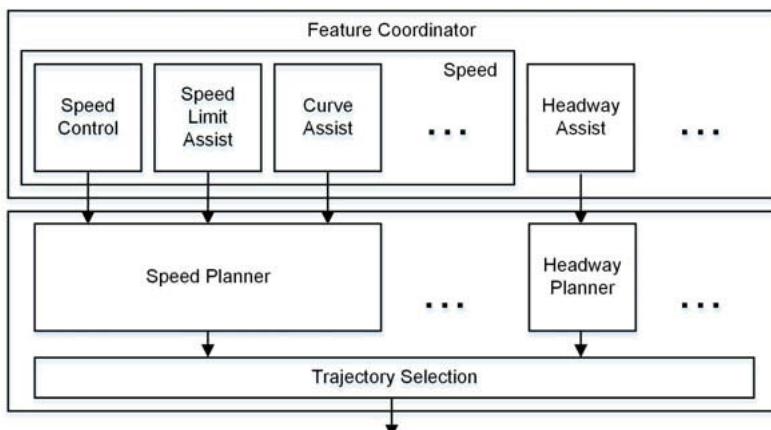


Bild 1: Struktur des Trajektorienplaners

Die Koordinationsebene ist modular aufgebaut und enthält für jede abgrenzbare Funktionalität des Systems ein unabhängiges Modul. Jedes Modul bietet eine intuitive Schnittstelle zur Applikation der jeweiligen Funktionalität. Dafür übersetzt und reduziert das Modul die Vielzahl der Optimierungsparameter des angesteuerten Trajektorienplaners (Gewichtungen im Gütemaß, Zustandsbeschränkungen, Suchraumgrenzen) auf wenige Parameter zur zielgerichteten Parametrierung der jeweiligen Funktionalität. Hierbei sind auch komplexere Algorithmen denkbar, die das Verhalten in kompletten Szenarien steuern.

Teilweise kann die Koordinationsebene die Arbitrierung zwischen unterschiedlichen Funktionalitäten übernehmen. Beispielsweise können die Anforderungen und Zielzustände von Funktionen zur Geschwindigkeitsregelung (auf Basis von Fahrervorgaben, prädiktiver Verkehrsschilderkennung oder prädiktiver Kurvenerkennung) verglichen und nur die kritischste Anforderung an den Planer für Geschwindigkeitstrajektorien weitergeleitet werden. Selbes gilt für die Arbitrierung von Sicherheits- und Komfortfunktionen. So übersteuert eine Anforderung des Notbremsassistenten stets eine ACC-Anforderung. Dagegen kann es bei der Abstandsregelung notwendig sein, mehrere Planer für Wegtrajektorien parallel zu berechnen, da sich häufig mehrere Zielobjekte in direkter Fahrzeugumgebung befinden und nicht immer vorab das kritischste Objekt bekannt ist und zur Planung ausgewählt werden kann. Beispielsweise kann hier ein Szenario betrachtet werden, in dem das Überholen auf dem „langsameren“ Fahrstreifen mit Zielobjekten im eigenen und im benachbarten, „schnelleren“ Fahrstreifen verhindert werden soll. Um bei zunehmender Anzahl relevanter Objekte den Ressourcenbedarf einzuschränken, können bzw. sollten diese zusätzlichen Planer für Wegtrajektorien nach Möglichkeit einfacher (bspw. durch eingegrenzte/gröbere Rasterung des Suchraums) als der Hauptplaner ausgelegt werden.

Zusammengefasst ermöglicht der modulare Aufbau der Koordinationsschicht die getrennte Parametrierung und Applikation einzelner Funktionalitäten unter Nutzung der gleichen Planerarchitektur und damit eine einfache Erweiterbarkeit des Systems um zukünftige Funktionalitäten.

## 5. Berechnung von mehrteiligen Trajektorien

Die analytische Lösung des Optimalsteuerungsproblems in [8] und [9] beschreibt die Systemzustände (Weg  $s$ , Geschwindigkeit  $v$ , Beschleunigung  $a$  und je nach Systemmodell Ruck  $r$ ) durch Polynome. Die Polynome weisen dabei den Nachteil auf, dass sie Maximalwerte für

Ruck und Beschleunigung nur punktuell erreichen und nicht abschnittsweise konstant halten können.

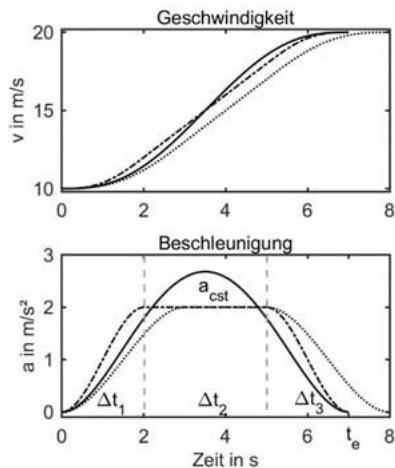


Bild 2: Geschwindigkeitstrajektorien: einteilig (—), dreiteilig mit festen (···) und dreiteilig (—) mit optimierten Flanken

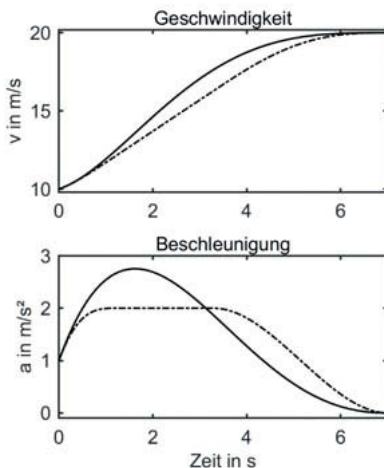


Bild 3: Unsymmetrische Geschwindigkeitstrajektorien: einteilig (—) und dreiteilig mit optimierten Flanken (—·—)

Bild 2 zeigt die Geschwindigkeit und die Beschleunigung einer beispielhaften einteiligen Trajektorie einer Geschwindigkeitsplanung. In diesem Beispiel wird die Geschwindigkeit von 10 m/s auf 20 m/s erhöht, wobei eine Beschleunigungsbeschränkung von  $2 \text{ m/s}^2$  wirksam ist. Da die berechnete Trajektorie die Beschleunigungsbeschränkung verletzt, wird sie von Werring in [8] als unzulässig eingestuft und verworfen. Um das Beschleunigungsvermögen des Fahrzeugs besser auszunutzen, schlägt Rathgeber in [9] die Berechnung von dreiteiligen Trajektorien vor. In Bild 2 ist eine solche dreiteilige Trajektorie zusätzlich zu der einteiligen Trajektorie abgebildet. Darin führt das erste Trajektoriensegment die Beschleunigung auf den maximal bzw. minimal zulässigen Wert  $a_{\text{cst}}$ , das zweite Segment hält die Beschleunigung konstant und das dritte Segment baut die Beschleunigung wieder ab. Rathgeber schlägt eine konstante Dauer für das erste und dritte Trajektoriensegments vor und variiert die Dauer des zweiten Segments so, dass die gewünschte Endgeschwindigkeit erreicht wird. Dies hat zur Folge, dass die Dauer  $t_e$  der dreiteiligen Trajektorie im Allgemeinen von der Dauer der einteiligen Trajektorie abweicht (siehe Bild 2).

Das Ersetzen einer einteiligen Trajektorie durch eine solche dreiteilige Trajektorie bei der Berechnung der Trajektorienschär führt zu einer Inkonsistenz bei der anschließenden Trajektorienauswahl, da die Trajektoriellänge in das Gütemaß eingeht. Ein weiterer Nachteil von Rathgebbers Ansatz folgt aus der invarianten Wahl der Dauer für das erste und dritte Trajektoriensegment, welche sich nicht an konkrete Situationen (z.B. Anfangsbeschleunigung ungleich 0 m/s<sup>2</sup>) anpassen (vergleiche Szenario in Bild 3).

Im Folgenden wird die Berechnung von dreiteiligen Geschwindigkeitstrajektorien mit variabler Dauer aller Trajektoriensegmente unter Einhaltung der Gesamtdauer  $t_e$  der zugrundeliegenden einteiligen Trajektorie vorgeschlagen. Die Dauer der jeweiligen Segmente folgt aus der Minimierung eines Gütemaßes. Das gewählte Gütemaß bewertet den Einsatz der Stellgröße am Eingang des Systemmodells und entspricht in dieser Hinsicht dem Integralanteil des Gütemaßes zur Auswahl einteiliger Trajektorien aus der Trajektorienschär (siehe [8] und [9]). Aufgrund der konsistenten Trajektoriendauer und des konsistenten Gütemaßes von ein- und dreiteiligen Trajektorien lassen sich diese in der überlagerten Optimierung direkt austauschen.

Damit eine dreiteilige Trajektorie die vorgegebene Geschwindigkeitsänderung  $v_e - v_0$  erzielt, muss folgende Gleichung erfüllt sein:

$$\int_0^{\Delta t_1} a_1 dt + \int_0^{\Delta t_2} a_{\text{cst}} dt + \int_0^{\Delta t_3} a_3 dt = v_e - v_0. \quad (1)$$

Die gesamte Trajektoriellänge  $t_e$  entspricht der Summe von  $\Delta t_1$ ,  $\Delta t_2$  und  $\Delta t_3$ . Die Beschleunigungen  $a_1$  und  $a_3$  im ersten und im dritten Segment werden durch Polynome 3. Ordnung beschrieben. Das Einsetzen von  $a_1$  und  $a_3$  in Gleichung 1 führt auf die quadratische Gleichung

$$A \cdot \Delta t_1^2 + B \cdot \Delta t_1 + C(\Delta t_3, t_e) = 0 \quad (2)$$

mit den Konstanten  $A$  und  $B$  sowie der Funktion  $C$ , wenn  $\Delta t_3$  und  $t_e$  als freie Parameter angenommen werden. Das heißt  $\Delta t_1$  kann für sinnvoll gewählte Werte von  $\Delta t_3$  berechnet werden und die resultierende dreiteilige Trajektorie behält die geforderte Länge  $t_e$ . Es zeigt sich, dass bei zwei gültigen Lösungen für  $\Delta t_1$  die kleinere zu einem kleineren Gütemaß führt. Die Dauer  $\Delta t_3$  wird so gewählt, dass das Gütemaß der dreiteiligen Trajektorie minimal wird. Hierfür wird eine unterlagerte Optimierung eingesetzt. In einem ersten Schritt wird der mögliche Lösungsbereich für  $\Delta t_3$  bestimmt. Dabei gelten folgende Randbedingungen

$$0 \leq t_{1,2,3} \leq t_e \quad | \quad t_{1,2,3} \in \mathbb{R}, \quad (3)$$

deren Berücksichtigung zu drei Ungleichungen führt.

In einem zweiten Schritt kann das optimale  $\Delta t_3$  beispielsweise durch ein Bisektionsverfahren gefunden werden. Mit diesem ergibt sich nach wenigen Rechenschritten ein optimaler Ersatz für die einteilige Trajektorie. In Bild 2 ist die so berechnete dreiteilige Trajektorie dargestellt. Ein weiteres Beispiel ist in Bild 3 dargestellt, bei dem eine nichtsymmetrische Trajektorie berechnet wird.

## 6. Berechnung des Sollzustands der Trajektorie

Eine Herausforderung in der Praxis ist die Planung konsistenter und komfortabler Trajektorien bei dynamischen Manövern. Die Trajektorienplanung erfordert eine Prädiktion des Zustands des Zielfahrzeugs in die Zukunft. Die Effekte von Rauschen und Sprüngen in den Eingangsdaten werden damit verstärkt und es kommt zu unstetigen Sollzustandsvorgaben für die Planung. Die Folge ist ein unruhiges und als unsicher wahrgenommenes Verhalten.

Der Sollabstand  $d_w$  bei einer Folgefahrt kann durch folgende Gleichung berechnet werden:

$$d_w = d_{\text{stop}} + v_t \cdot \text{headway}. \quad (4)$$

Darin steht  $d_{\text{stop}}$  für den Abstand zum Zielfahrzeug im Stillstand,  $v_t$  für die Geschwindigkeit des Zielfahrzeugs und headway für die geforderte Zeitlücke. Die zukünftige Sollposition  $s_w$  des Egofahrzeugs entspricht dann der Differenz zwischen prädizierter Position des Zielfahrzeugs und Sollabstand

$$s_w = s_t - d_w = s_t - d_{\text{stop}} - v_t \cdot \text{headway} \quad (5a)$$

und die Sollzustände  $v_w$  und  $a_w$  ergeben sich durch Ableiten von Gleichung (5a):

$$v_w = v_t - a_t \cdot \text{headway} \quad (5b)$$

$$a_w = a_t. \quad (5c)$$

Die Bewegung des Zielfahrzeugs wird unter der Annahme einer konstanten Beschleunigung in die Zukunft prädiziert.

In Bild 4 sind beispielhafte Zustandsverläufe (Weg, Geschwindigkeit und Beschleunigung) eines Zielfahrzeugs und die resultierenden Sollzustände dargestellt. Es ist zu erkennen, dass bei sprunghafter Änderung der Zielfahrzeugsbeschleunigung (tritt in der Praxis u.a. durch ungenaue Messungen auf) die prädizierte Sollgeschwindigkeit um  $-a_t \cdot \text{headway}$  springt (siehe Gleichung 5b). Infolgedessen wird bei Beginn einer Bremsung des Zielfahrzeugs (ab 11 s bis 16 s) eine Sollgeschwindigkeit oberhalb der Zielfahrzeuggeschwindigkeit angefordert und die

Trajektorienplanung sucht Lösungen, die das Fahrzeug beschleunigen statt, wie eigentlich erwartet, verzögern; das Fahrzeug wird vom kleiner werdenden Sollabstand angezogen. Umgekehrt springt die Sollgeschwindigkeit auf null, wenn das prädiizierte Zielfahrzeug zum Stillstand kommt. Dieser Sprung in der Sollzustandsvorgabe führt ungünstigerweise dazu, dass das Fahrzeug mit einer zu hohen Geschwindigkeit und kleinem Abstand einem anhaltenden Zielfahrzeug folgt. Umgekehrt wächst beim Anfahren des Zielfahrzeugs aus dem Stillstand der Sollabstand, sodass die Sollwerte für die Planung zunächst bei negativen Geschwindigkeiten liegen und das stehende Fahrzeug „zurückdrücken“.

Um diese Problematik zu lösen, wird hier eine in allen Zuständen konsistente Filterung des Zielfahrzeugzustandes vorgeschlagen. Diese Filterung kann anschaulich als ein Masse-Feder-Dämpfer-System dargestellt werden, das am Zielfahrzeug befestigt ist. Der Sollabstand  $d_w$  entspricht dabei der entspannten Federlänge und der Zustand der Masse wird als neuer Sollzustand für die Planung verwendet. In Bild 4 ist der gefilterte Sollzustand dargestellt. Bei einer Bremsung des Zielfahrzeugs (ab 11 s bis 16 s) konvergieren die Sollgeschwindigkeit und die Sollbeschleunigung nun stetig zu dem durch Gleichung 5 vorgegebenen Sollwert. In

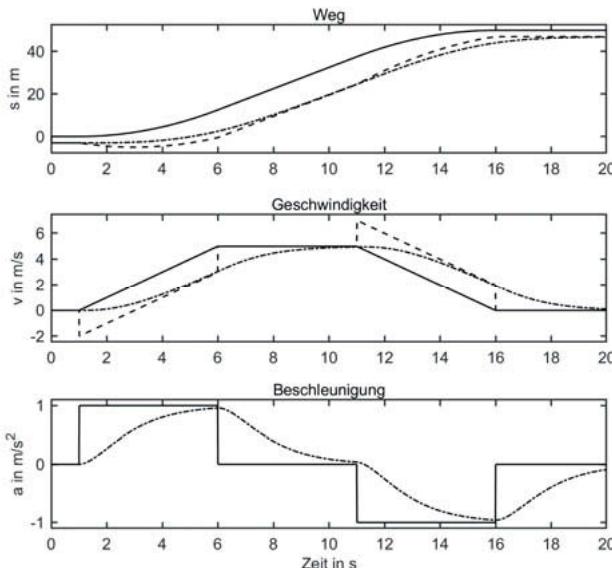


Bild 4: Zustand vom Zielfahrzeug (—) und Zielzustände für die Trajektorienplanung: nach der Abstandsgleichung (5) (—) und nach Filterung mit dem Masse-Feder-Dämpfer-System (---)

diesem Szenario ist der Sollabstand größer als der durch Gleichung 5 berechnete Sollabstand und ermöglicht ein Bremsen in den Stillstand, ohne dass die Sollzustände der Trajektorienplanung Unstetigkeiten aufweisen. Ein großer Vorzug des virtuellen Masse-Feder-Dämpfer-Systems ist weiterhin, dass im Trajektorienplaner die Dämpfung explizit als Parameter zur Verfügung steht. Auf diese Weise kann das Thema der Kolonnenstabilität direkt adressiert werden.

## 7. Stop-And-Go

Die Stop-And-Go Funktionalität ermöglicht es, einem vorausfahrenden Fahrzeug bis in den Stillstand zu folgen und hinter diesem wieder anzufahren. Theoretisch ist diese Funktionalität durch die beschriebene Trajektorienplanung abgedeckt. In der Praxis kann es durch Regelabweichungen (u.a. durch Totzeiten bei der Ansteuerung der Bremse und des Antriebsstrangs), ständig variierende Zielfahrzeugdaten und die daraus resultierende Anpassung der Trajektorien zu Zeitschritten kommen, in denen keine geeignete Polynomtrajektorie gefunden wird. Oft tritt dies im letzten Teil der Bremsung kurz vor dem Stillstand auf und führt zu kritischen Situationen. Alle Trajektorien im Suchraum verletzen dann entweder die Ruck-/Beschleunigungsbeschränkungen und müssen zu stark bremsen oder sie verletzen die Geschwindigkeitsbeschränkung und müssen eintauchen und kurzzeitig rückwärtsfahren, um die geforderte Stoppdistanz zu erreichen.

Zunächst wirkt hier die in Abschnitt 6 vorgestellte Filterung der Zielfahrzeugdaten durch die Vorgabe glatter Sollzustände entgegen. Um die Robustheit der Planung weiter zu erhöhen, ohne dabei durch eine feinere Rasterung den Rechenaufwand stark zu erhöhen, können die Rasterpunkte im Suchraum adaptiv variiert werden. Darunter wird verstanden, dass sich die Rasterpunkte so verschieben, dass sich in der Nähe der besten Lösung mehr Rasterpunkte aufhalten als in weiter entfernten Bereichen. Es ist weiterhin wichtig, dass sich Rasterpunkte im gesamten Suchraum befinden, sodass auf sprunghafte Änderungen der Zielzustände schnell reagiert werden kann (z.B. Zielobjektwechsel, starkes Zielobjektbremsen usw.). Durch iterative Anpassung der Rasterpunkte über mehrere Zyklen der Optimierung hinweg, ist es möglich die Rasterung um einen ausgewählten Punkt zu verfeinern und sich so dem Optimum anzunähern. Die Wahrscheinlichkeit, dass keine gültige Trajektorie gefunden wird, lässt sich so weiter reduzieren, jedoch kann nicht garantiert werden, dass immer eine gültige Lösung gefunden wird.

Aufgrund der fehlenden Möglichkeit „Einzutauchen“ ist der Anhaltevorgang besonders herausfordernd. Auftretende Abweichungen zwischen geplanter und tatsächlich gefahrener Trajektorie können nicht ohne weiteres korrigiert werden, da dies häufig Abschnitte mit negativer Geschwindigkeit (Rückwärtsfahrt) erfordert. Verschiedene Erweiterungen sind als Lösungsansatz für diese Problematik denkbar. Eine davon ist die Überblendung der Trajektorienplanung bei sehr niedrigen Geschwindigkeiten mit einer virtuellen Stoßstange [11].

Eine virtuelle Stoßstange stellt ein Feder-Dämpfer-System dar, das zwischen Fahrzeug und Zielfahrzeug virtuell befestigt wird. Durch geeignete Auslegung kann sie das Fahrzeug mit einem vorgegebenen Abstand zum Zielfahrzeug bis in den Stillstand führen, bei niedrigen Geschwindigkeiten folgen und auch hinter dem Zielfahrzeug anfahren. In Kombination mit der in Abschnitt 6 vorgestellten Filterung des Sollabstands ist es weiterhin möglich Betriebszustände zu definieren, die eine comfortable Übergabe zwischen Trajektorienplanung und virtueller Stoßstange erlauben. Die virtuelle Stoßstange bietet zusätzlich eine sichere Rückfallebene für den Fall, dass die Primärplanung keine Trajektorie im Lösungsraum findet, da ein stets definierter, analytischer Zusammenhang zwischen Ziel- und Egofahrzeug zur Berechnung der geforderten Beschleunigung hergestellt wird.

## 8. Ausblick

Mehrteilige Trajektorien für die Abstandsplanung können ähnlich wie für die in Abschnitt 5 vorgestellte Geschwindigkeitsplanung berechnet werden. Aufgrund der komplexeren Gleichungen sind jedoch mehrere Fälle zu unterscheiden, die den Rechenaufwand erhöhen. Für eine Implementierung in der Praxis sollten effizientere und eventuell approximative Berechnungsverfahren untersucht werden.

Die Realisierung der virtuellen Stoßstange in Abschnitt 7 mittels eines Feder-Dämpfer-Systems entspricht dem Einsatz eines linearen Reglers. Wie in Abschnitt 3 beschrieben, bieten lineare Konzepte nur wenige Freiheitsgrade zum Einstellen des gewünschten Verhaltens. Um stark variierende Kundenanforderungen auch im Bereich niedriger Geschwindigkeiten berücksichtigen zu können, sind Erweiterungen des linearen Ansatzes denkbar.

## Literaturangaben

- [1] Gruschwitz, D.; Hölscher, J.; Raudszus, D. u. Zlocki, A.: Marktdurchdringung von Fahrzeugsicherheitssystemen 2015. In: Berichte der Bundesanstalt für Straßenwesen, Unterreihe „Mensch und Sicherheit“ M 272, 2017.
- [2] Swaroop, D. u. Huandra, R.: Intelligent Cruise Control System Design Based on a Traffic Flow Specification. In: California PATH Research Report UCB-ITS-PRR-99-5, 1999.
- [3] Bengtsson, J.: Adaptive Cruise Control and Driver Modeling. Lund Institute of Technology, 2001.
- [4] Widmann, G. R.; Daniels, M. K.; Hamilton, L.; Humm, L.; Riley, B.; Schiffmann, J. K.; Schnelker, D. E. u. Wishon, H. W.: Comparison of Lidar-Based and Radar-Based Adaptive Cruise Control Systems. In: SAE2000 World Congress, 2000.
- [5] Eigel, T.: Integrierte Längs- und Querführung von Personenkraftwagen mittels Sliding-Mode-Regelung. Technischen Universität Carolo-Wilhelmina zu Braunschweig, 2010.
- [6] Germann, S. u. Isermann, R.: Nonlinear distance and cruise control for passenger cars. In: IFAC Advances in Automotive Control, 1995.
- [7] Cherian, M. u. Saithiyar, S. P.: Neural Network based ACC for Optimized Safety and Comfort. In: International Journal of Computer Applications 42 (14), 2012.
- [8] Werling, M.: Ein neues Konzept für die Trajektoriengenerierung und -stabilisierung in zeitkritischen Verkehrsszenarien. KIT Scientific Publishing, Karlsruhe, 2011.
- [9] Rathgeber, C.: Trajektorienplanung und -folgeregelung für assistiertes bis hochautomatisiertes Fahren. Technische Universität Berlin, 2016.
- [10] Werling, M.; Gröll, L. u. Breithauer, G.: Ein Multiregler zur Erprobung vollautonomen Fahrens. In: at – Automatisierungstechnik 56 (11), 2008, S. 585 – 591.
- [11] Gorjestani, A.; Shankwitz, C. u. Donath, M.: Impedance Control for Truck Collision Avoidance. In: Proceedings of the American Control Conference, 2000.

# Vorsteuerungsentwurf für einen robusten Zwei-Freiheitsgrade Schlupfregler für Antiblockiersysteme

## Prefilter Design for a Robust Two-Degrees-of-Freedom Wheelslip Controller for Anti-lock Braking Systems

**P. Vogt, M.Sc., S. Schulze, M.Sc., Dr.-Ing. E. Lenz,**

Prof. Dr.-Ing. **U. Konigorski**,

Technische Universität Darmstadt, Darmstadt;

Dipl.-Ing. **A. Klug**, Dipl.-Ing. **H. Westerfeld**,

Robert Bosch GmbH, Abstatt

### Kurzfassung

In der vorliegenden Arbeit wird eine Erweiterung der in [12] vorgeschlagenen robusten Zwei-Freiheitsgrade Reglerstruktur für einen Schlupfregler zur Verwendung in Antiblockiersystemen beschrieben. Die Erweiterung besteht in der Verwendung einer Vorsteuerung, die zum einen durch Verwendung eines Nickmodells für alle Räder auch bei dynamischen Radlastveränderungen das reale Fahrzeugverhalten besser abbilden kann und zum anderen durch Verwendung eines nichtlinearen Hydraulikmodells das reale Aktorverhalten, insbesondere beim erstmaligen Druckaufbau, genauer berücksichtigt wird. Dieses Modell wird mittels der Methode der exakten Eingangs-/Ausgangslinearisierung geregelt, um die Vorsteuerstellgröße und die Solltrajektorie für den Radschlupfregler zu liefern, wodurch ein besseres Führungsverhalten als in [12] erreicht wird.

**Schlüsselwörter:** Antiblockiersystem, Robuste Regelung, Vorsteuerungsentwurf, Polplatzierung, hydraulischer Aktor, Nickmodell, modellbasierte Regelung.

### Abstract

In this work, the robust two-degrees-of-freedom structure for wheel slip control presented in [12] is extended to a prefilter that contains a model for the full vehicle's pitch dynamics to incorporate load transfer into the model as well as a nonlinear actuator model, which is able to reflect the real actuator behavior better, especially for the first pressure increase from 0 bar. The model is controlled with the method of exact feedback linearization in order to calculate the desired slip and a control signal, which leads to better tracking than in the case of a single wheel used in [12].

**Index Terms:** Ani-lock Braking, Robust Control, Prefilter Design, Pole Placement, Hydraulic Actuator, Pitch Model, Model-based Control.

## 1. EINLEITUNG

Die Hauptaufgabe des Antiblockiersystems (ABS) besteht in der radindividuellen Regelung des Bremsmomentes, um ein Blockieren der Räder zu verhindern und so eine hohe Kraftschlussausnutzung und Lenkbarkeit zu gewährleisten. Dies wird im klassischen ABS durch Umschalten zwischen verschiedenen Bremsmomentniveaus in Abhängigkeit von der Raddrehzahl und -beschleunigung erreicht (siehe z. B. [9, S. 90 f.]), während in neueren Ansätzen kontinuierliche modellbasierte Regler zum Einsatz kommen, wie bspw. in [10] oder den in [1] angegebenen Referenzen. In dieser Arbeit wird ein solcher Regler um eine Vorsteuerung, die ein Gesamtfahrzeugmodell und ein nichtlineares Hydraulikmodell enthält, erweitert.

## 2. MODELLBILDUNG

Als Modell für den Reglerentwurf wird im Gegensatz zu [12] kein Viertelfahrzeug, sondern ein Gesamtfahrzeugmodell mit Nick- und Hubfreiheitsgrad zur Abbildung des Lastwechselverhaltens beim Bremsen verwendet. Zum Modellieren des Reifen-Straße-Kontaktes wird als zentrales Element ein Modell für den Reibwert  $\mu$  in Abhängigkeit des Reifenschlupfes

$$\lambda = \frac{v - \omega r}{v} \quad (1)$$

benötigt, das in der vorliegenden Arbeit durch das sog. PACEJKA-Modell

$$\mu(\lambda) = \mu_0 D \sin \left( C \arctan \left( B \lambda - E (B \lambda - \arctan(B \lambda)) \right) \right) \quad (2)$$

nach [8] gegeben ist, über das sich die Reifenkraft zu

$$F_x = \mu(\lambda) F_z$$

angeben lässt. Mit diesem lassen sich die NEWTON'schen Gleichungen in  $x$ - und  $z$ -Richtung sowie die Kreiselgleichung für den Nickwinkel  $\theta$  für das in Abbildung 1 dargestellte Fahrzeug angeben. Da nur der Fall des Geradeausbremsens betrachtet werden soll, wird keine Quer-, Gier- und Wankdynamik modelliert, sie ließe sich bei Bedarf jedoch noch in das verwendete Modell einfügen. Es ergeben sich mit dem

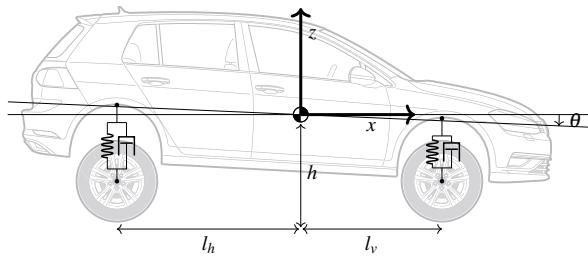


Abbildung 1: Fahrzeug mit Koordinatensystemen nach [3, S. 14].

Reifenmodell und den dynamischen Aufstandskräften  $F_{z,\text{dyn}}$  die Differentialgleichungen

$$\dot{v} = \frac{-F_{x,\text{VL}} - F_{x,\text{HL}} - F_{x,\text{HR}} - F_{x,\text{VR}} - c_w A \frac{\rho}{2} v^2}{m} - \dot{\theta} \dot{z} \quad (3)$$

in  $x$ -Richtung in Abhängigkeit der Gesamtfahrzeuggmasse  $m$ , des Strömungswiderstandskoeffizienten  $c_w$ , der Querschnittsfläche  $A$  und des Luftdruckes  $\rho$  sowie

$$\ddot{z} = \frac{F_{z,\text{dyn},\text{VL}} + F_{z,\text{dyn},\text{HL}} + F_{z,\text{dyn},\text{HR}} + F_{z,\text{dyn},\text{VR}}}{m_A} + \dot{\theta} v \quad (4)$$

in  $z$ -Richtung in Abhängigkeit der Aufbaumasse  $m_A$ . Für die Nickdynamik ergibt sich

$$\ddot{\theta} = \frac{(F_{z,\text{dyn},\text{HL}} + F_{z,\text{dyn},\text{HR}})l_h - (F_{z,\text{dyn},\text{VL}} + F_{z,\text{dyn},\text{VR}})l_v - m\dot{v}(h + z)}{J_y} \quad (5)$$

mit dem Nickträgheitsmoment des Aufbaus  $J_y$  und der Schwerpunktshöhe  $h$  sowie den Schwerpunktsabständen  $l_v$  und  $l_h$  wie in Abbildung 1 dargestellt. Die dynamischen Aufstands Kräfte  $F_{z,\text{dyn}}$  ergeben sich über die aus den Aufbaufedern und Aufbaudämpfern resultierenden Kräften zu

$$F_{z,\text{dyn},\text{VL}} = c_v(-z + l_v \sin(\theta)) + d_v(-\dot{z} + l_v \cos(\theta) \dot{\theta}) \quad (6a)$$

$$F_{z,\text{dyn},\text{HL}} = c_h(-z - l_h \sin(\theta)) + d_h(-\dot{z} - l_h \cos(\theta) \dot{\theta}) \quad (6b)$$

$$F_{z,\text{dyn},\text{HR}} = c_h(-z - l_h \sin(\theta)) + d_h(-\dot{z} - l_h \cos(\theta) \dot{\theta}) \quad (6c)$$

$$F_{z,\text{dyn},\text{VR}} = c_v(-z + l_v \sin(\theta)) + d_v(-\dot{z} + l_v \cos(\theta) \dot{\theta}) \quad (6d)$$

und die gesamte Aufstands Kraft erhält man aus einer Überlagerung der statischen Aufstands Kräfte

$$F_{z,\text{stat},v} = \frac{m_A g l_h}{l_h + l_v} \quad (7a)$$

$$F_{z,\text{stat},h} = \frac{m_A g l_v}{l_h + l_v} \quad (7b)$$

mit den dynamischen Aufstandskräften und den Gewichtskräften der Räder  $m_R$  und Radträger  $m_{RT}$  zu

$$F_{z,VL} = gm_{RT,VL} + gm_{R,VL} + \frac{F_{z,stat,v}}{2} + F_{z,dyn,VL} \quad (8a)$$

$$F_{z,HL} = gm_{RT,HL} + gm_{R,HL} + \frac{F_{z,stat,h}}{2} + F_{z,dyn,HL} \quad (8b)$$

$$F_{z,HR} = gm_{RT,HR} + gm_{R,HR} + \frac{F_{z,stat,h}}{2} + F_{z,dyn,HR} \quad (8c)$$

$$F_{z,VR} = gm_{RT,VR} + gm_{R,VR} + \frac{F_{z,stat,v}}{2} + F_{z,dyn,VR} \quad (8d)$$

Zuletzt wird noch die Differentialgleichung des Schlupfes der vier Räder  $i \in \{VL, HL, HR, VR\}$  benötigt, die sich analog zum in [12] betrachteten Fall einer Einzelradregelung zu

$$\dot{\lambda}_i = \frac{\dot{v}_x}{v_x} (1 - \lambda_i) + \frac{r_i}{J_i v_x} (M_{B,i} - r_i F_{x,i}) + \frac{d_i (1 - \lambda_i)}{J_i} \quad (9)$$

ergibt.

Neben dem Modell für das Fahrzeug wird ein Modell für den Bremsenaktor benötigt. Dies ist in der vorliegenden Arbeit ein hydraulisches Bremssystem, da eine Bremshydraulik bei Serienfahrzeugen am häufigsten verwendet wird. Um das reale Verhalten des Aktors in der zu entwerfenden Vorsteuerung besser abbilden zu können, wird die Hydraulik als ein nichtlineares  $PT_1$ -Glied und der Zusammenhang zwischen Bremsmoment und Bremsdruck durch

$$M_B = c^* r_B A_K p_{ist} \quad (10)$$

mit dem Bremsscheibenradius  $r_B$ , der Bremszylinderfläche  $A_K$  und dem inneren Bremsenübersetzungsverhältnis  $c^*$  modelliert. Dazu werden Druckverläufe von ABS-Bremsungen verwendet, um ein LoLIMoT-Modell (Local Linear Model Tree) nach [5] zu trainieren. Dieses zerlegt den Raum der Eingangs- und Ausgangsgrößen, d. h. den Raum von  $M_{B,soll}$  und  $M_B$ , automatisiert so, dass für jeden Teilbereich ein lokal gültiges lineares Modell mit dem höchsten Gütefunktionswert einer für die Identifikation vorgebbaren Gütefunktion identifiziert werden kann. Der Gesamtausgang des Modells ergibt sich durch Überlagerung der Teilmodelle mittels radialer Basisfunktionen als Aktivierungsfunktionen für die verschiedenen Ausgänge der lokalen Modelle, wie in Abbildung 2 schematisch dargestellt. Die Modellgleichung eines LoLIMoT-Modells lässt sich durch Verwendung von  $N$  lokalen linearen Modellen der Form

$$x_{k+1}^i = s_b^i x_k^i + a^i u_k \quad (11)$$

mit den Systemmatrizen  $s_b^i$  und den Steuermatrizen  $a^i$  und so genannter *Zugehörigkeitsfunktionen* beste-

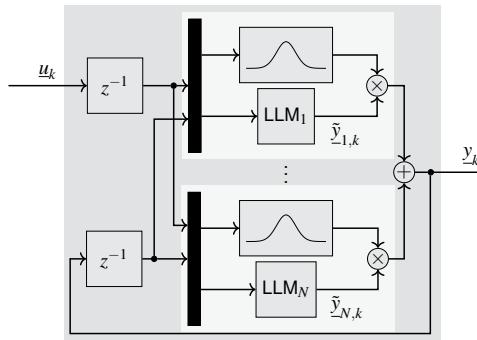


Abbildung 2: Blockschaltbild eines LoLiMoT-Modells nach [5, S. 603].

hend aus den radialen Basisfunktionen

$$\phi(\underline{x}, i) = e^{-\frac{(x_1 - \mu_{1i})^2}{2\sigma_{1i}^2} - \dots - \frac{(x_n - \mu_{ni})^2}{2\sigma_{ni}^2}} \quad (12)$$

mit den Zentrumskoordinaten  $\mu_{ji}$ , den Standardabweichungen  $\sigma_{ji}$  des  $i$ -ten Modells und des  $j$ -ten Modellgültigkeitsbereiches, die die *Aktivierungsfunktionen*

$$\Phi(\underline{x}, i) = \frac{\phi(\underline{x}, i)}{\sum_{j=1}^N \phi(\underline{x}, j)} \quad (13)$$

bilden, zu

$$M_{B,k+1} = \sum_{i=1}^N (s_b^i M_{B,k} + a^i M_{B,soll,k}) \Phi \left( \begin{bmatrix} M_{B,k} \\ M_{B,soll,k} \end{bmatrix}, i \right) \quad (14)$$

angeben, wobei

$$\sum_{i=1}^N \Phi(\underline{x}, i) = 1 \quad (15)$$

gilt [6, S. 846].

Da in der Regelstrategie die Modellgleichung des Aktors invertiert werden muss, wird im Folgenden angegeben, wie sich dies für das LoLiMoT-Modell in Gl. (14) erreichen lässt. Aufgrund der Abhängigkeit des gesuchten Stelleinganges  $M_{B,soll,k}$  von Termen der Form  $x e^{x^2}$  ist eine analytische Lösung des Inversionsproblems nicht möglich und es muss ein numerisches Verfahren gefunden werden. Ein Ansatz dazu ist in [7] angegeben, der darauf basiert, die Modellgleichung in einen bekannten Teil, der von den bekannten aktuellen und vorangegangenen Ausgängen und Eingängen sowie den gewünschten zukünftigen Ausgängen abhängt, und einen unbekannten Teil, der von den zu ermittelnden Eingängen abhängt, für den die Zugehörigkeitsfunktionen durch stückweise lineare Funktionen auf dem Gültigkeitsbereich der lokalen

Modelle ersetzt werden, zu zerlegen. Dazu wird zuerst der Modellausgang Gl. (14) zu

$$M_{B,k+1} = \sum_{i=1}^N \underbrace{s_b^i M_{B,k} e^{-\frac{(M_{B,k}-\mu_{1i})^2}{2\sigma_{1i}^2}}}_{y_c} \underbrace{e^{-\frac{(M_{B,soll,k}-\mu_{2i})^2}{2\sigma_{2i}^2}}}_{\phi_u} + a^i M_{B,soll,k} e^{-\frac{(M_{B,k}-\mu_{1i})^2}{2\sigma_{1i}^2}} e^{-\frac{(M_{B,soll,k}-\mu_{2i})^2}{2\sigma_{2i}^2}} \sum_{j=1}^N e^{-\frac{(M_{B,k}-\mu_{1j})^2}{2\sigma_{1j}^2}} - \frac{(M_{B,soll,k}-\mu_{2j})^2}{2\sigma_{2j}^2} \quad (16)$$

berechnet. Anschließend wird der vom gesuchten Eingang abhängige Anteil der Zugehörigkeitsfunktion durch

$$\phi_u = \begin{cases} \frac{\beta}{\sigma_{2i}} (M_{B,soll,k} - \mu_{2i}) + 1, & \mu_{2i} - \frac{\sigma_{2i}}{\beta} \leq M_{B,soll,k} < \mu_{2i} \\ \frac{\beta}{\sigma_{2i}} (-M_{B,soll,k} + \mu_{2i}) + 1, & \mu_{2i} \leq M_{B,soll,k} \leq \mu_{2i} + \frac{\sigma_{2i}}{\beta} \end{cases} \quad (17)$$

mit einem Parameter  $\beta$  ersetzt und die Gleichung in das quadratische Polynom

$$0 = \sum_{i=1}^N \left( a^i \phi_c \left( \mp \frac{\beta}{\sigma_{2i}} + 1 \right) - (M_{B,k+1} - y_c) \phi_c \left( \pm \frac{\beta}{\sigma_{2i}} \right) \right) M_{B,soll,k} + \dots \\ \dots + \sum_{i=1}^N \pm a^i \phi_c \frac{\beta}{\sigma_{2i}} M_{B,soll,k}^2 - \sum_{i=1}^N (M_{B,k+1} - y_c) \phi_c \left( \mp \frac{\beta}{\sigma_{2i}} + 1 \right) \quad (18)$$

umgeformt [4, S. 265]. Dieses kann nun für die Gültigkeitsbereiche der lokalen Modelle gelöst werden, sodass  $2N$  mögliche Lösungen entstehen, die auf ihre Eignung geprüft werden müssen. In [4, S. 268 f.] sind Methoden angegeben, mit denen sich im Voraus der zu untersuchende Bereich möglicher Lösungen verkleinern lässt, um die Berechnungszeit zu verringern. Anstatt der Zugehörigkeitsfunktionen Gl. (12) können nach [7] auch Summen von GAUSSglocken oder nach [2] beliebige Zugehörigkeitsfunktionen verwendet werden. Wie sich im vorliegenden Fall gezeigt hat, sind die Inversionsfehler durch die Abhängigkeit der Nichtlinearität von der gesuchten Stellgröße allerdings teilweise so groß, dass der invertierte Eingang unrealistische Werte annimmt. Dies ist insbesondere deshalb problematisch, weil zwar der gewünschte Ausgang auch mit der fehlerhaften Stellgröße fast exakt erreicht wird und damit die Schlupfsoltrajektorie weiterhin realistisch bleibt, jedoch die berechnete Stellgröße die reale Strecke nicht in den gewünschten Arbeitspunkt steuern kann. Daher wird für den eigentlichen Reglerentwurf ein vereinfachtes Modell verwendet, dessen Zugehörigkeitsfunktionen nur vom Zustand und nicht mehr von der Stellgröße abhängen, sodass sich Gl. (14) zu

$$M_{B,k+1}^i = s_b^i M_{B,k} + a^i M_{B,soll,k} \quad (19a)$$

$$M_{B,k+1} = \sum_{i=0}^N M_{B,k+1}^i \frac{e^{-\left(\frac{M_{B,k}-\mu^i}{\sqrt{2}\sigma^i}\right)^2}}{\sum_{j=0}^N e^{-\left(\frac{M_{B,k}-\mu^j}{\sqrt{2}\sigma^j}\right)^2}} \quad (19b)$$

vereinfacht und sich der gesuchte Eingang analytisch mittels

$$M_{B,soll,k} = \frac{M_{B,k+1} - \sum_{i=0}^N s_b^i M_{B,k} \frac{e^{-\left(\frac{M_{B,k}-\mu^i}{\sqrt{2}\sigma^i}\right)^2}}{\sum_{j=0}^N e^{-\left(\frac{M_{B,k}-\mu^j}{\sqrt{2}\sigma^j}\right)^2}}}{\sum_{i=0}^N a^i \frac{e^{-\left(\frac{M_{B,k}-\mu^i}{\sqrt{2}\sigma^i}\right)^2}}{\sum_{j=0}^N e^{-\left(\frac{M_{B,k}-\mu^j}{\sqrt{2}\sigma^j}\right)^2}}} \quad (20)$$

berechnen lässt.

### 3. REGELUNG

Der Fokus dieser Arbeit liegt auf der Beschreibung der Vorsteuerung der in Abbildung 3 gezeigten Reglerstruktur bestehend aus der modellbasierten Vorsteuerung, für die hier ein Modell des gesamten Fahrzeugs verwendet wird, und einer mit Verfahren der robusten Polbereichsvorgabe entworfenen Regelung mit Gain-Scheduling, die in [12] beschrieben ist. Da der Regler inklusive Vorsteuerung auf einem Mikro-

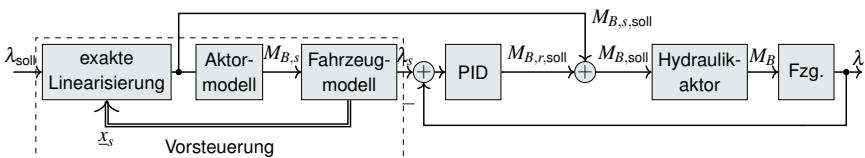


Abbildung 3: Blockschaltbild der Reglerstruktur

controller laufen soll, muss der Entwurf der Regelung zeitdiskret durchgeführt werden, wozu die kontinuierliche Dynamik des Fahrzeugmodells mit dem Verfahren von EULER und der Abtastzeit  $T$  zu

$$\underline{x}_{k+1} = \underline{x}_k + T \underline{f}(\underline{x}_k, \underline{u}_k) = \underline{f}_d(\underline{x}_k, \underline{u}_k) \quad (21)$$

diskretisiert wird. Anschließend werden die vier Radschlüpfen innerhalb der Vorsteuerung mit der Methode der exakten Eingangs-/Ausgangslinearisierung geregelt, um daraus den Sollwert für die Radschlüpfen  $\lambda_s$  und die Vorsteuertrajektorie für die Stellgröße  $M_{B,s}$  zu generieren. Die Schlupfregler der einzelnen Räder werden weiterhin mit der in [12] beschriebenen Methode für ein Einzelradmodell entworfen.

Zur Regelung mit exakter Linearisierung muss zuerst eine Transformation aufgestellt werden, die das Fahrzeugmodell in die BYRNES-ISIDORI-Normalform überführt. Diese lässt sich nach [11, S. 1924f] er-

mitteln, indem die zukünftigen Ausgänge des Systems so lange berechnet werden, bis eine der  $q$  Stellgrößen in einem davon zum ersten Mal direkt auftritt. Das heißt, es wird für jeden Ausgang  $y_{i,k}$  eine Differenzordnung  $\delta_i$  gesucht, für den zum ersten Mal

$$y_{i,k+\delta} = \begin{cases} \sum_{j=0}^q \frac{\partial}{\partial u_{j,k}} c_i \left( \bigcap_{d=0}^{\delta_i-1} f_d(\underline{x}, \underline{u}_{k+d}), \underline{u}_{k+\delta_i} \right) \neq 0, & \delta_i > 0 \\ \sum_{j=0}^q \frac{\partial}{\partial u_{j,k}} c_i(\underline{x}_k, \underline{u}_k) \neq 0, & \delta_i = 0 \end{cases} \quad (22)$$

gilt. Dies ist für das Fahrzeugmodell mit dem Ausgang

$$\underline{y}_k = \begin{bmatrix} \lambda_{VL,k} & \lambda_{HL,k} & \lambda_{HR,k} & \lambda_{VR,k} \end{bmatrix}^T \quad (23)$$

für alle vier Radschlüsse bei  $\underline{y}_{k+2}$  der Fall, sodass sich der relative Grad der vier Ausgänge zu  $\underline{\delta} = [2 \ 2 \ 2 \ 2]^T$  ergibt und damit die Differenzordnung des Fahrzeugs  $\delta = 8$  beträgt. Da die Systemordnung  $n = 13 > 8 = \delta$  ist, existiert eine interne Dynamik der Ordnung 5, die gerade der Längs-, Vertikal- und Nickdynamik des Fahrzeugs entspricht. Die Transformation  $\underline{t}(\underline{x}_k)$  in linearisierende Koordinaten  $\underline{\tilde{x}}_k$  ergibt sich damit zu

$$\underline{\tilde{x}}_k = \begin{bmatrix} \lambda_{VL,k} & \lambda_{VL,k+1} & \lambda_{HL,k} & \lambda_{HL,k+1} & \lambda_{HR,k} & \lambda_{HR,k+1} & \lambda_{VR,k} & \lambda_{VR,k+1} & v_k & z_k & \dot{z}_k & \theta_k & \dot{\theta}_k \end{bmatrix}^T. \quad (24)$$

Da die Differenzengleichungen für die vier Räder abgesehen von der Parametrierung identisch sind, wird im Folgenden die für alle vier Räder strukturell identische Differenzengleichung

$$\begin{bmatrix} \lambda_{k+1} \\ \lambda_{k+2} \end{bmatrix} = \begin{bmatrix} \lambda_k + T \left( \frac{(1-\lambda_k)v_k}{v_k} + \frac{rM_{B,k}-r^2F_{y_k}}{Jv_k} + d\frac{1-\lambda_k}{J} \right) \\ \lambda_{k+1} + T \left( \frac{(1-\lambda_{k+1})v_{k+1}}{v_{k+1}} + \frac{rb(M_{B,k}M_{B,\text{ soll },k})-r^2F_{y_{k+1}}}{Jv_{k+1}} + d\frac{1-\lambda_{k+1}}{J} \right) \end{bmatrix} \quad (25)$$

betrachtet, der die lineare Dynamik

$$\begin{bmatrix} \lambda_{k+1} \\ \lambda_{k+2} \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ -a_0 & -a_1 \end{bmatrix} \begin{bmatrix} \lambda_k \\ \lambda_{k+1} \end{bmatrix} + \begin{bmatrix} 0 \\ b_0 \end{bmatrix} \lambda_{\text{ soll },k} \quad (26)$$

aufgeprägt werden soll. Die Terme

$$v_{k+1} = v_k + T \left( \frac{-F_{x,VL,k} - F_{x,HL,k} - F_{x,HR,k} - F_{x,VR,k} - c_w A \frac{\rho}{2} v_k^2 - \dot{\theta}_k \dot{z}_k}{m} \right) \quad (27a)$$

$$F_{x,k+1} = F_{z,k+1} \mu(\lambda_{k+1}) \quad (27b)$$

$$\dot{v}_{k+1} = \frac{-F_{x,VL,k+1} - F_{x,HL,k+1} - F_{x,HR,k+1} - F_{x,VR,k+1} - c_w A \frac{\rho}{2} v_{k+1}^2 - \dot{\theta}_{k+1} \dot{z}_{k+1}}{m} \quad (27c)$$

ergeben sich dabei durch Vorwärtssimulation der internen Dynamik des Fahrzeugs und Einsetzen der diskreten Größen in Gl. (8). Das Regelgesetz für ein Rad erhält man schließlich aus Gl. (25) durch Kompen-sation der nichtlinearen Terme und Hinzufügen eines Zustandsreglers zu

$$M_{B,\text{soll}} = b^{-1} \left( \frac{J(v_k + Ta_k)}{rT} \left( -T \left( \frac{\left( \frac{1-\lambda_{k+1}}{m} \dot{v}_{k+1} - F_{z,k+1} \mu(\lambda_{k+1}) \frac{r^2}{J} \right)}{v_k + Ta_k} + \dots \right. \right. \right. \right. \\ \left. \left. \left. \left. \dots + \frac{d}{J} (1 - \lambda_{k+1}) \right) - \lambda_{k+1} - r_0 \lambda_k - r_1 \lambda_{k+1} + f \lambda_{\text{soll},k} \right) , M_{B,k} \right) , \quad (28)$$

wobei  $b^{-1}$  dem Zusammenhang aus Gl. (20) bzw. der inversen Beziehung für das LoLiMoT-Modell entspricht. Wird dieses Regelgesetz auf alle vier Räder mit den jeweiligen Parametern angewandt, ergibt sich insgesamt ein System mit linearem Eingangs-/Ausgangsverhalten und der Übertragungsmatrix

$$\begin{bmatrix} \lambda_{VL,k} \\ \lambda_{HL,k} \\ \lambda_{HR,k} \\ \lambda_{VR,k} \end{bmatrix} = \begin{bmatrix} \frac{f}{z^2 + r_1 z + r_0} & 0 & 0 & 0 \\ 0 & \frac{f}{z^2 + r_1 z + r_0} & 0 & 0 \\ 0 & 0 & \frac{f}{z^2 + r_1 z + r_0} & 0 \\ 0 & 0 & 0 & \frac{f}{z^2 + r_1 z + r_0} \end{bmatrix} \begin{bmatrix} \lambda_{\text{soll},VL,k} \\ \lambda_{\text{soll},HL,k} \\ \lambda_{\text{soll},HR,k} \\ \lambda_{\text{soll},VR,k} \end{bmatrix} , \quad (29)$$

die die Schläpfe der vier Räder entkoppelt. Die Entkopplung ist immer erreichbar, da die Regelung in der Vorsteuerung auf ein simuliertes System angewandt wird, dessen Parameter exakt bekannt sind und so weder Modellungsgenauigkeiten noch Störungen auftreten.

Da in der entstehenden Übertragungsmatrix in den einzelnen Übertragungspfaden keine Nullstelle vorhanden ist und damit die Differenzordnung 2 beträgt, für die Abbildung des kontinuierlichen Systems bei Verwendung eines Abtast-Haltegliedes aber nach [13, S. 182] eine Differenzordnung von 1 nötig wäre, kann die bei der Diskretisierung der kontinuierlichen Wunschübertragungsfunktion entstehende Nullstelle erzeugt werden, indem anstatt  $\lambda_k$  der nichtlineare Ausgang

$$\tilde{y}_k = f_0 \lambda_k + f_1 \left( \lambda_k + T \left( \frac{1 - \lambda_k}{mv_k} \dot{v}_k - \frac{F_{z,k} \mu(\lambda_k) \frac{r^2}{J}}{v_k} + \frac{d}{J} (1 - \lambda_k) + \frac{r}{Jv_k} M_{B,k} \right) \right) \quad (30)$$

für das geregelte System verwendet wird, was in  $\tilde{x}$ -Koordinaten zur Übertragungsfunktion

$$G_{\lambda \leftarrow M_{B,\text{soll}}} (z) = \frac{f_1 z + f_0}{z^2 + r_1 z + r_0}$$

führt, die durch geeignete Wahl der Koeffizienten  $f_0$  und  $f_1$  mit der Diskretisierung der kontinuierlichen Wunschübertragungsfunktion in Übereinstimmung gebracht werden kann.

## 4. ERGEBNISSE

Im Folgenden werden die Simulationsergebnisse der vorgeschlagenen Reglerstruktur für unterschiedliche Reibwerte in der Vorsteuerung gezeigt. Die Regler der einzelnen Räder sind dabei identisch zu [12] ausgelegt und parametrisiert und die Vorsteuerung mit den Fahrzeugparametern aus [14] versehen. Die Simulation wird bei  $v = 150 \frac{\text{km}}{\text{h}}$  und sonst verschwindenden Anfangswerten gestartet, bei  $t = 1 \text{ s}$  wird ein Sollschlupf von 0,05 und bei  $t = 3 \text{ s}$  ein Sollschlupf von 0,1, was dem Maximum der Reibwertkurve entspricht, vorgegeben. Bei  $t = 4 \text{ s}$  wird der Reibwert auf  $\mu = 0,75\mu_0$  abgesenkt. Für den Fall identischer Reibwerte  $\mu_0 = 1$  in Vorsteuerung und realer Strecke ist in Abbildung 4 zu sehen, dass die Regelung bedingt durch das nichtlineare Hydraulikmodell besser als im Fall eines linearen Hydraulikmodells in der Lage ist, den Druckaufbau beim Anbremsen abzubilden und somit das Überschwingen zu reduzieren. Da durch das Nickmodell im Fahrzeugmodell auch die Aufstandskraftänderungen beim Bremsen abgebildet werden können, wird das Einstellen eines Solldruckes, der dies berücksichtigt, bereits in der Vorsteuerung erledigt, wodurch die eigentliche Regelung die Achslaständerung nicht mehr als Störung, die ausgeregelt werden muss, zu sehen bekommt, was die Regelergebnisse weiter verbessert. In Abbildung 5 und Abbil-

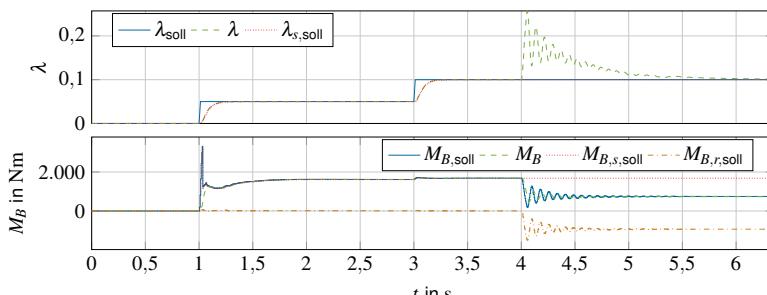


Abbildung 4: Simulationsergebnisse für Übereinstimmung der Reibwerte in Vorsteuerung und Strecke.

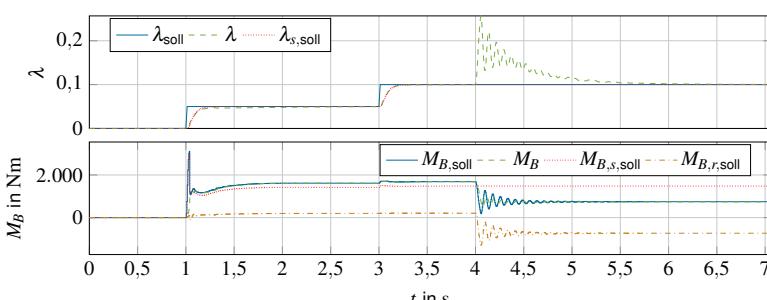


Abbildung 5: Simulationsergebnisse für  $0,9\mu_0$  in der Vorsteuerung.

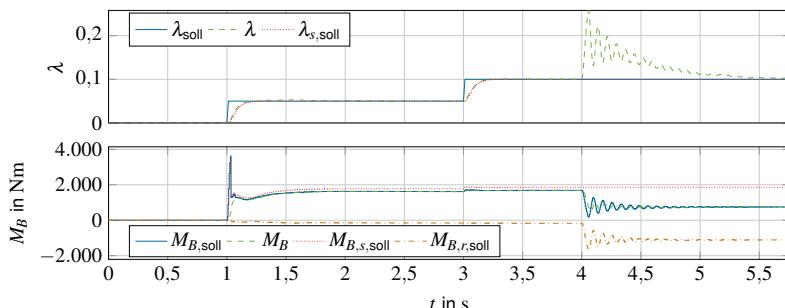


Abbildung 6: Simulationsergebnisse für  $1,1\mu_0$  in der Vorsteuerung.

dung 6 sind die Schlupfverläufe für zu niedrigen bzw. zu hohen Reibwert in der Vorsteuerung dargestellt und es ist zu sehen, dass auch in diesem Fall die Regelung dem Sollwert folgen kann, obwohl das Über- schwingen größer ist als ohne Abweichung.

## 5. ZUSAMMENFASSUNG UND AUSBLICK

In der vorliegenden Arbeit wurde die in [12] vorgestellte Reglerstruktur um eine modellbasierte Vorsteuerung, die ein Gesamtfahrzeugmodell sowie ein nichtlineares Hydraulikmodell enthält, erweitert und simulativ deren Funktionsfähigkeit an einem Gesamtfahrzeugmodell für unterschiedliche Reibwerte in Vorsteuerung und Fahrzeugmodell getestet. Im Weiteren ist das Regelkonzept noch an einem realen Fahrzeug zu testen und auf seine Eignung für den Einsatz in einem ABS-System zu prüfen.

## LITERATUR

- [1] ALY, A. A., E.-S. ZEIDAN, A. HAMED und F. SALEM: *An Antilock-Braking Systems (ABS) Control. A Technical Review*. In: *Intelligent Control and Automation*, 02, 03, S. 186–195, 2011.
- [2] EULER-ROLLE, N., I. ŠKRJANC, C. HAMETNER und S. JAKUBEK: *Automated generation of feedforward control using feedback linearization of local model networks*. In: *Engineering Applications of Artificial Intelligence*, 50, S. 320–330, 2016.
- [3] HOEDT, J.: *Fahrdynamikregelung für fehltolerante X-By-Wire-Antriebstopologien*. Institut für Automatisierungstechnik. Dissertation. Technische Universität Darmstadt, Darmstadt, 2013.
- [4] MERCORELLI, P. und M. NENTWIG: *Model Inversion Using Fuzzy Neural Network with Boosting of the Solution*. In: *International Journal of Pure and Applied Mathematics*, 80, 2, S. 261–270, 2012.

- [5] NELLES, O.: *Nonlinear System Identification*. Springer, Berlin, Heidelberg, 2001. ISBN: 978-3-642-08674-8.
- [6] NELLES, O., A. FINK und R. ISERMANN: *Local Linear Model Trees (LOLIMOT) Toolbox for Nonlinear System Identification*. In: *IFAC Proceedings Volumes*, 33, 15, S. 845–850, 2000.
- [7] NENTWIG, M. und P. MERCORELLI: *Inversion of Fuzzy Neural Networks for the Reduction of Noise in the Control Loop*. In: *IFAC Proceedings Volumes*, 41, 3, S. 157–162, 2008.
- [8] PACEJKA, H. B.: *Tire and vehicle dynamics*. 3. Aufl. Butterworth-Heinemann, Oxford, 2012. ISBN: 978-0-08-097016-5.
- [9] REIF, K.: *Bremsen und Bremsregelsysteme*. 1. Aufl. Vieweg+Teubner, Wiesbaden, 2010. ISBN: 978-3-8348-1311-4.
- [10] SEMMLER, S.: *Regelung der Fahrzeugbremsdynamik mit kontinuierlich einstellbaren Radbremsen*. Dissertation. Technische Universität Darmstadt, Darmstadt, 2006.
- [11] SOROUSH, M. und C. KRAVARIS: *Discrete-time nonlinear controller synthesis by input/output linearization*. In: *AIChE Journal*, 38, 12, S. 1923–1945, 1992.
- [12] VOGT, P., E. LENZ, A. KLUG, H. WESTERFELD und U. KONIGORSKI: *Robust Two-Degree-of-Freedom Wheel Slip Controller Structure for Anti-lock Braking*. In: *9th Symposium on Advances in Automotive Control (AAC 19)*, 2019.
- [13] WESTERMAIER, C.: *Zeitdiskrete adaptive Regelung mit allgemeinem Referenzmodell bei instabilen Diskretisierungsnulstellen*. Dissertation. Technische Universität München, München, 2014.
- [14] WOHLRAB, S.: *Einflussanalyse von Parametervariationen am Fahrzeug auf die Fahrdynamik und die charakteristischen Kennwerte in standardisierten Fahrmanövern*. Fahrzeugtechnik. Masterarbeit. Technische Universität Darmstadt, Darmstadt, 2016.

# Intelligentes Fahrwerk – Datenquelle Cloud

M.Sc. **Andreas Noll**, Dr.-Ing. **Ralf Schwarz**,

Dipl.-Ing. **David Reitze**,

Audi AG, Ingolstadt;

M.Sc. **Konstantin Riedl**,

Lehrstuhl für Fahrzeugtechnik (FTM), Technische Universität München

## Kurzfassung

Im Mittelpunkt der vorliegenden Arbeit steht die konkrete Umsetzung einer vorausschauenden adaptiven (=präadaptiven) Fahrwerksregelung im Automobilbereich mit dem Schwerpunkt der Schwarmdatengenerierung und -verarbeitung. Hierzu wird ein konkretes Konzept eines „intelligenten Fahrwerks“ entwickelt, welches cloudbasierte Straßenzustandsinformationen nutzt, um situativ auf zukünftige Ereignisse im Fahrbahnverlauf zu reagieren. Hierfür werden die von den Fahrzeugen gesammelten Straßeninformationen in der Cloud ausgewertet und in einer Daten-Infrastruktur hinterlegt. Das Ziel ist es, aus den gesammelten Daten (Umfeldbeschreibung, Alltagssituationen, Bedienhandlungen, etc.) in der Cloud zu lernen und neue fahrwerk-relevante Informationen zu generieren, um das Fahrwerk zukünftig prädiktiv anzusteuern, so dass der Fahrkomfort optimiert, die Reichweite gesteigert und Aufsetzvorgänge bzw. wiederholende Fahrerbedienhandlungen vermieden werden.

## 1. Einleitung

In heutigen Fahrzeugen kommen bereits viele unterschiedliche geregelte Vertikaldynamiksysteme zum Einsatz [1], die das Fahrverhalten hinsichtlich Fahrkomfort gegenüber passiven Fahrzeugen verbessern. Hierzu gehören Komponenten wie Verstellämpfer, Luftfederung und eine aktive Wankstabilisierung. Aktuelle Ansätze verwenden darüber hinaus eine Kopplung von bestehenden aktiven Vertikal- und Preview-Systemen (vorausschauende Systeme), welche auf Grundlage von kamera- und laserbasierten Daten prädiktive Streckeninformationen generieren. Alle diese Regelsysteme verfolgen i.d.R. das Ziel der situationsabhängigen Komfort- bzw. Fahrdynamikoptimierung und beschränken sich dabei auf das durch Sensoren erfassbare Fahrzeugumfeld. Die gleichzeitige Steigerung der Reichweiteeffizienz bzw.  $CO_2$ -Reduktion wird meist parallel anderen, nicht vertikaldynamischen Komponenten zugeordnet, wie bspw. rekuperativen Bremssystemen [2] zur Energierückgewinnung oder einem intelligenten Motormanagement zur Abschaltung des Verbrennungsmotors im lastfreien Fahrzustand [3].

In naher Zukunft werden jedoch die nicht prädiktiven aktiven und semi-aktiven vertikaldynamischen Regeleinheiten in ihren Eigenschaften ausgereift sein. D.h. die Komforteigenschaften können mit den aktuellen Systemkomponenten nicht mehr entscheidend verbessert werden, da diese bzgl. der Dynamik der Akteure und der vorhandenen Fahrzeugsensorik ausgereizt sind. Auch die zurzeit verwendeten Preview-Systeme sind in ihrer Funktionalität begrenzt. Aufgrund von wechselnden Umgebungsbedingungen und begrenzten Erfassungsbereichen von Sensoren wie Kamera, Laser usw. neigen diese zu Fehldetections, da sie in ihrer Prädiktion eingeschränkt sind. Entsprechend sieht es bei den effizienzsteigernden Systemen aus. Als Folge der Elektro- und Hybridmobilität ist die Automobilindustrie besonders daran interessiert den Energieverbrauch ihrer Fahrzeuge zu senken, in dem eine immer niedrigere Trimmlage für eine maximale Reichweite angestrebt wird [4]. Demgegenüber stehen alltägliche Fahrmanöver wie bspw. Bordsteinabfahrten, Bodenwellen, etc. die bei zu geringer Niveaulage zum Aufsetzen des Fahrzeugs führen können. Um auf diese gegensätzlichen Anforderungen zu reagieren, werden definierte Fahrmanöver während der Entwicklung durchgeführt und Schutzkonzepte für bspw. HV-Batterien im Unterboden abgeleitet. Aber auch hier ist ein Umdenken notwendig. Einzelkomponenten werden in Zukunft keine entscheidenden Vorteile liefern, die gezielte Vernetzung der unterschiedlichen Systeme ist in diesem Zusammenhang zielführend. Eine weitere Möglichkeit den Fahrkomfort und die Reichweiteeffizienz gegenüber den bereits bekannten vorausschauenden Systemen zu verbessern, sind cloudbasierte Fahrwerksfunktionen wie bspw. das in [5] vorgestellte Konzept einer präadaptiven Dämpfer- und/oder Niveauregulierung. Dabei wird ein großer Teil der benötigten Daten direkt im Fahrzeug generiert [6] und durch eine entsprechende Fahrzeug-Server-Schnittstelle (Car-2-X) zur Verfügung gestellt. Durch die zusätzliche (kartenbasierte) Informationsquelle, lässt sich anschließend das bereits in [7] aufgezeigte Potenzial von prädiktiven Streckendaten nutzen, um bestehende Vertikaldynamiksysteme präadaptiv zu parametrieren und zu optimieren [8].

Im Rahmen dieser Arbeit wird das Konzept eines „intelligenten Fahrwerks“ von [9] mit Cloud-Datenanbindung (Car-2-X Applications [10] - [12]) und Schwarmdatenintelligenz aufgegriffen und um zusätzliche Informationen aus der Cloud erweitert, welche sich nicht direkt bzw. nur unter großen Rechenaufwand im Fahrzeug ermitteln lassen. Das Ziel ist es, aus den gesammelten Daten (Umfeldbeschreibung, Alltagssituationen, Bedienhandlungen etc.) in der Cloud zu lernen und neue fahrwerkrelevante Informationen zu generieren, sodass u.a. der Fahrkomfort durch Präadaptierung der Verstelldämpfer optimiert und mit Hilfe einer langsam-aktiven Niveauregulierung die Reichweiteeffizienz gesteigert bzw. der Bodenfreigang sichergestellt wird, in dem die Fahrzeugtrimmlage gebietsweise angepasst wird. In diesem Zusammenhang

soll erneut auf die Funktionsarchitektur zur Straßenzustandsschätzung und Einzelhindernisdetektion nach [6] bzw. [8] im Fahrzeug eingegangen werden. Zudem erfolgt in diesem Beitrag die Herleitung eines Verfahrens zur Detektion relevanter Gebiete hinsichtlich Niveaulage des Fahrzeugs in der Cloud.

## 2. Vorstellung des Konzepts Intelligentes Fahrwerk nach [9]

Im folgenden Abschnitt wird das Grundkonzept eines „intelligenten Fahrwerks“ mit Cloud-Datenanbindung (globale Serverdaten) und Schwarmdatenintelligenz vorgestellt. Durch die zusätzliche (globale) Informationsquelle lassen sich bestehende Vertikaldynamiksysteme präadaptiv adaptieren und plausibilisieren. Hierfür werden die gesammelten Straßeninformationen von den Fahrzeugen sowohl im Fahrzeug als auch in der Cloud ausgewertet und in einer lokalen bzw. globalen Daten-Infrastruktur hinterlegt. Das Ziel ist es, die aggregierten Informationen in einer digitalen Straßenzustandskarte zusammenzufassen und über eine Car-2-X-Schnittstelle den Verkehrsteilnehmern zur Verfügung zu stellen. Zudem werden die fahrzeugspezifischen gelernten Informationen mit eingebunden. Auf diese Weise ist jedes Fahrzeug auch ohne vorausschauende Sensorik, wie bspw. Kamera oder Radar, in der Lage, auf bevorstehende Ereignisse im Fahrbahnverlauf zu reagieren bzw. durch eine Warnung den Fahrer entsprechend zu informieren.

Die Grundlage für das Konzept eines „intelligenten Fahrwerks“ bildet eine aktives Luftfeder- system, mit deren Hilfe sich die Niveaulage des Fahrzeugs bei wechselnden Beladungszu- ständen im Sekundenbereich variieren lässt, um so die Fahrsicherheit, die fahrdynamischen Eigenschaften sowie den Bodenfreigang sicherzustellen. Hinzu kommt eine elektronische Dämpferregelung, welche die Dämpfungseigenschaften des Stoßdämpfers automatisch an die Fahrsituation anpasst, sodass die Aufbaubewegungen des Fahrzeugs minimiert und der Kontakt zwischen Reifen und Fahrbahn permanent sichergestellt bzw. die Radlastschwankungen reduziert werden.

In der Literatur finden sich zu der Thematik cloudbasierter Fahrzeugfunktionen bereits ver- schiedene Einsatzbereich. In [10] wird bspw. ein Konzept zur Optimierung der Routenplanung auf Basis der aktuellen Verkehrsfluss- und Straßenzustandsinformationen aufgezeigt. Zum anderen erfolgt in [11] die Berechnung eines optimalen Dämpfermodus durch Integration der Riccati-Differentialgleichungen rückwärts in der Zeit über den Vorausschau-Horizont, wobei die Berechnungen von verschiedenen Fahrzeugparametern und der Fahrzeuggeschwindigkeit abhängen, sowie von einem definierten deterministischen Straßenprofil, welches durch cloud- basierte stochastische Straßen- und Schlaglochinformationen überlagert wird. [12] bietet dar- über hinaus einen Überblick über weitere Car-2-X Use Cases hinsichtlich aktiver Sicherheit

und Effizienzsteigerung des Verkehrsflusses inkl. Kommunikations- und Übertragungstyp. Dabei werden als Datenbasis Infrastruktur-Informationen in Form von Ampelphasen, Stauinformationen, Verkehrsdichte usw. verwendet.

Bei dem Konzept eines „intelligenten Fahrwerks“ nach [9] erfolgt im Gegensatz zu den aus der Literatur bekannten cloudbasierten Funktionen die Optimierung der Fahrwerksysteme durch präadaptive (=vorausschauende adaptive) Parametrierung des Regelgesetzes in Analogie zu [8]. Hierdurch kann die bestehende (konventionelle) Dämpfer- bzw. Niveauregulierung mit und ohne Vorausschau unkompliziert erweitert werden. Zudem wird das Potenzial von fahrzeugspezifischen Informationen mit berücksichtigt. Durch Verifizierung des Grundreglers kann zusätzlich im Entwicklungsprozess ein Parameterraum appliziert werden, in dem der Regelkreis stabil ist. Auf diese Weise wird eine Fehlfunktion im späteren Serieneinsatz durch eine nicht abgesicherte Konstellation von Eingangsdaten verhindert.

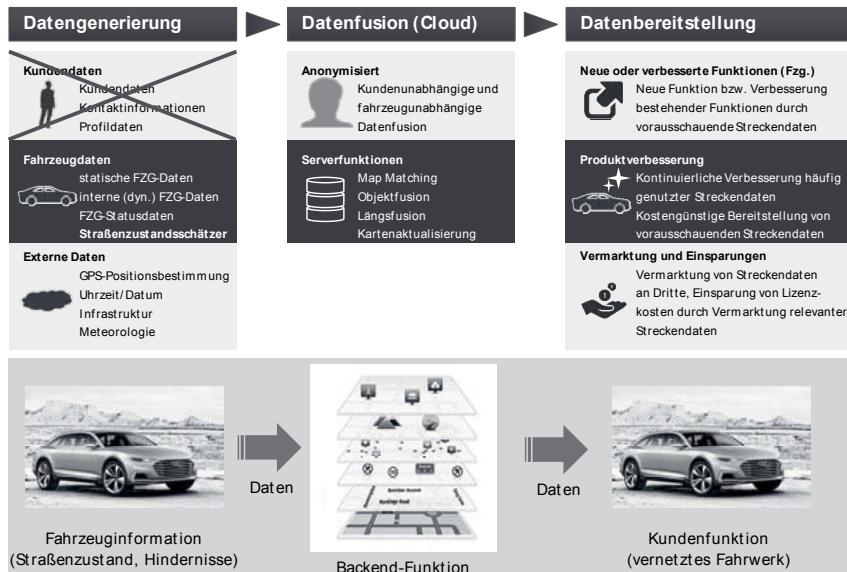


Bild 1: Teilbereiche einer vernetzten, cloudbasierten Fahrwerksfunktion nach [8]

Nach [8] lässt sich eine vernetzte, cloudbasierte Fahrwerksfunktion prinzipiell in drei Teilbereiche gliedern, siehe Bild 1. Zu Beginn erfolgt die Datengenerierung im Fahrzeug. Dabei wird mit Hilfe der Fahrzeugsensorik und externen Datenquellen das Fahrzeugumfeld, welches für die Fahrwerkregelfunktion relevant ist, möglichst exakt beschrieben. Eine Echtzeitanforderung

an die Erkennung besteht dabei nicht, da die Datengenerierung und die Datenverwendung voneinander entkoppelt sind, siehe Bild 1. Dadurch ist der Einsatz von vorausschauenden Systemen, wie z.B. Kamera- oder LIDAR-Systeme, nicht zwangsläufig notwendig. An mittlerer Stelle befindet sich die Datenfusion in der Cloud. Hier werden die übertragenden Informationen zunächst in einer (eventbasierten) Datenbank mit GPS-Referenz gesammelt. Anschließend erfolgt die Verarbeitung der gesammelten Informationen mit dem Ziel einer aggregierten digitalen Straßenzustandskarte, welche im letzten Schritt den Fahrzeugen zur Verfügung gestellt werden, sodass bestehende Systeme, wie z.B. das vorgestellte Konzept einer präadaptiven Dämpfer- bzw. Niveauregulierung in [5], erweitert und verbessert werden können. [8]

### 3. Datengenerierung im Fahrzeug

In der Literatur finden sich zu dieser Thematik bereits verschiedene Umsetzungen. So können die notwendigen Straßeninformationen auf Basis der Untersuchungen von [6], [8], [13] mit Hilfe eines modell- bzw. signalbasierten Straßenbeobachters generiert werden. Der betrachtete Frequenzbereich der geschätzten Höhensignale beträgt nach [8], [13] dabei ca. 0.5 bis 15 Hz, was ebenso Einzelhindernisse wie bspw. Tempeschwellen und Schlaglöcher mit einschließt. Die Schätzung eines absoluten (niederfrequenten) Höhenprofils, wie es bspw. von Navigationssystemen zur Verfügung gestellt wird, ist mit dieser Methode jedoch nicht möglich.

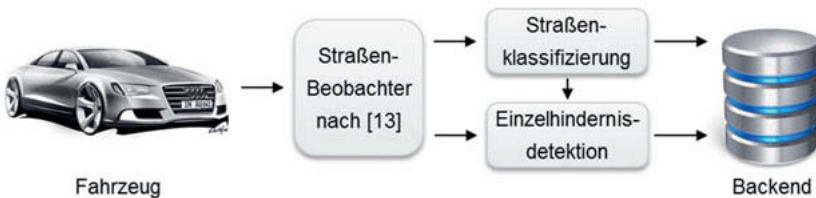


Bild 2: Blockschaltbild der einseitigen Datenübertragung vom Fahrzeug zur Cloud [5]

In [6], [8] wird dieser Beobachteransatz anschließend aufgegriffen und entsprechend um eine Straßenklassifizierung und Einzelhindernisdetektion im Fahrzeug erweitert, siehe Bild 2. Mit Hilfe des Straßenbeobachters erfolgt dabei die Bewertung der gesamten Straße in zwei Schritten. Zum einen wird der Straßenzustand nach ISO8608:1995(E) [14] auf Basis der Betrachtung des Frequenzbereichs ermittelt. Und zum anderen erfolgt die Detektion der Einzelhindernisse im Zeitbereich. Für weiterführende Literatur sei an dieser Stelle auf [8], [15], [16] verwiesen.

Somit kann sowohl eine Aussage über den aktuellen Straßenzustand als auch über Einzelhindernisse im Fahrzeug getroffen werden. Die gewonnenen Daten werden am Ende positionsabhängig in die Cloud übertragen und über die Fahrzeugflotte plausibilisiert. Eine Aussage über einen möglichen Aufsetzvorgang der Fahrzeugkarosserie kann jedoch mit diesen Methoden nicht detektiert werden, weshalb in [9] ein Online-Verfahren hergeleitet wird, mit dessen Hilfe die benötigten Informationen für das Konzept eines „intelligente Fahrwerk“ bereitgestellt werden.

#### 4. Datenübertragung und -verarbeitung in der Cloud nach [5]

Für die Übertragung der Straßeninformationen zwischen Fahrzeug und Backend gibt es verschiedene Möglichkeiten. Je nach zeitlichen Anforderungen können die Daten über die Luftschnittstelle einzeln oder auch paketiert online (je nach Verfügbarkeit) mit Hilfe vom GSM-Standard bzw. UMTS oder LTE/5G bei höherer Datenrate übermittelt werden [17]. Sind die zeitlichen Anforderungen der Datenübertragung gering, so ist ebenfalls eine temporäre Datenübertragung via WLAN denkbar. Diese eignet sich jedoch nur, wenn die fahrzeugseitige Speicherkapazität entsprechend ausgelegt ist.

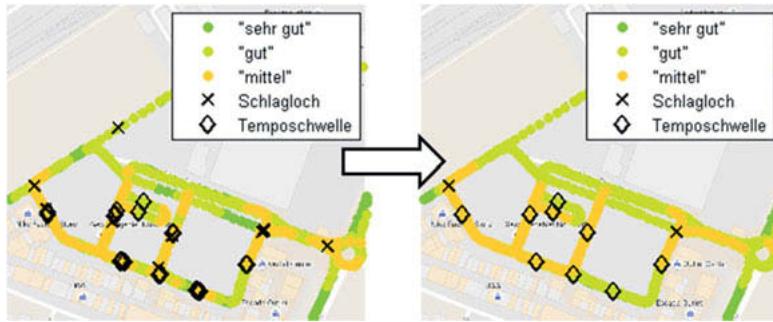


Bild 3: Konzept der Datenverarbeitung in der Cloud, ausgehend von den Schwarmdaten (Rohwerten) bei Mehrfachbefahrung links zu den aggregierten Daten rechts [5]

Das Ziel der Datenverarbeitung in der Cloud ist es, die gesammelten Schwarmdaten durch *Map Matching* [18] und *Clustering* [19] zu verknüpfen und anschließend neue Daten zu aggregieren. Im Fall der vorgestellten Straßenklassifizierung und Einzelhindernisdetection bedeutet dies, die Zuordnung der ermittelten Straßenkategorien und Einzelhindernisse zu einer digitalen Karte. Dieser Prozess wird als *Map Matching* bezeichnet. Sobald die verschiedenen Straßenabschnitte mehrfach von den Verkehrsteilnehmern befahren werden, erfolgt der zweite

Schritt der Verarbeitung, dass sogenannte *Clustering*. Dieser Prozess definiert die Zugehörigkeit der Daten unter verschiedenen Aspekten wie bspw. Objekttyp, Verortung oder zeitlicher Verfügbarkeit. Damit lassen sich im Anschluss der Event-Typ, die GSP-Position, die Richtungsabhängigkeit oder die Überfahrungswahrscheinlichkeit aggregieren und über Laufzeit aktualisieren, siehe Bild 3.

## 5. Datenverwendung im Fahrzeug

Nachdem die Straßenzustandsinformationen von einer Fahrzeugflotte gesammelt und anschließend in der Cloud zu einer digitalen Straßenzustandskarte aggregiert und die fahrzeugspezifischen (wiederholenden) Bedienhandlungen und detektierten Aufsetzvorgänge gespeichert wurden, erfolgt am Ende die Datenbereitstellung an die vernetzten Fahrzeuge bzw. in den Fahrwerksystemen. Ausgehend von der aktuellen Fahrzeugposition wird permanent die Aktualität der Straßenzustandskarte im Fahrzeug geprüft. Sollte die Karteninformationen veraltet sein, so findet eine Aktualisierung über die Luftschnittstelle statt. Auf diese Weise wird sichergestellt, dass im Fahrzeug auf aktuelle Straßenzustandsinformationen aus der Cloud zugegriffen wird und eine spätere Fehlparametrierung ausgeschlossen werden kann.

**Bemerkung:** Aufgrund der Trennung von der Datengenerierung und Datenverwendung, siehe Bild 1, stellen Kartendaten immer eine veraltete Informationsquelle dar. Dies bedeutet, dass zunächst eine Datenerhebung stattfinden muss, bevor eine digitale Straßenzustandskarte aggregiert werden kann. In der Zwischenzeit ist eine Änderung der Umgebungsbedingungen nicht auszuschließen, sodass zwischen den beiden Prozessen ein kontinuierlicher Zyklus bestehen muss. [8]

Im Anschluss erfolgt die Fahrerwunscherkennung in Form der wahrscheinlichsten Route (engl. most probable path) die vom Fahrzeug zurücklegt wird. Entweder ist diese durch eine gewünschte Routenführung bereits bekannt oder kann bspw. nach [20], [21] auf Grundlage der Verkehrssituation bzw. des Straßennetzes bestimmt werden. Auf diese Weise können die fahrwerksrelevanten (prädiktiven) Streckendaten in auftretender Reihenfolge selektiert und im Fahrwerk verarbeitet werden, indem bspw. die nach [8] ermittelten Regel- bzw. Fahrstrategien für unterschiedliche Fahrwerksystem verwendet werden, sodass am Ende des cloudbasierten präadaptiven Regelkonzepts eine situationsabhängige Fahrwerksadaption stattfindet.

**Bemerkung:** Der Vorteil der vorgestellten situationsabhängigen Adaption der Fahrwerksysteme gegenüber einer aktiven Vorsteuerung bzw. Kompensation ist, dass die Objektposition bzw. der Abstand zwischen Fahrzeug und Fahrbahnevent nicht exakt bekannt sein muss. Für eine Optimierung des Fahrverhaltens ist bereits ausreichend, wenn sich das Objekt innerhalb der zeitlich konstanten Regleradaptierung befindet. [8]

## 6. Cloudbasierte Generierung neuer fahrwerksrelevanten Umfeldinformationen

Um den Prozess der Datenverwendung im Fahrzeug zu optimieren, soll im Folgenden das vorhandene Potential der gesammelten Informationen in der Cloud aufgezeigt werden. Ziel ist es, mit Hilfe von georeferenzierten Einzelhindernisdetections und erkannten Aufsetzvorgängen des Fahrzeugs in alltäglichen Fahrsituationen, im Folgenden als kritische Hindernisse bezeichnet, relevante Gebiete für die Fahrzeugtrimmlage zu aggregieren. Hierfür soll am Beispiel eines exemplarischen Stadtgebietes, siehe Bild 4, mit einer hohen Anzahl künstlich angelegter Temposchwellen und kritischen Hindernissen, Gebiete definiert werden, in denen die Wahrscheinlichkeit einer solchen Hindernisüberfahrt sehr hoch ist. Auf diese Weise lässt sich eine erhöhte Fahrzeugtrimmlage im gesamten relevanten Gebiet für das entsprechende Fahrzeug vorgeben, sodass eine permanente situationsabhängige Niveaulagenänderung und damit eine Überbeanspruchung der Aktorik unterbunden wird.

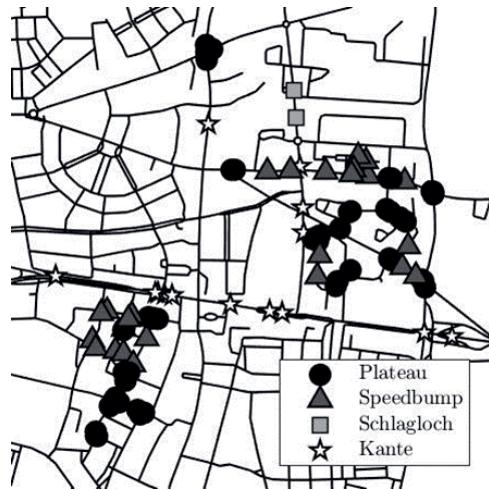


Bild 4: Straßenzustandskarte mit allen aggregierten Einzelhindernissen nach Kategorien

Für das Clustering der relevanten Gebiete gibt es prinzipiell verschiedene Möglichkeiten. Im gezeigten Anwendungsfall eignen sich vor allem die dichtebasierenden Verfahren wie der DBSCAN [22]. Eine Erweiterung mit standortabhängigen  $\varepsilon$ -Parameter, mit dessen Hilfe eine lokale Charakteristik wie die Straßentopologie berücksichtigt werden kann, stellt der ML-DBSCAN [23] dar. Die Nachbarschaftsbedingung und damit die Zugehörigkeit der Hindernisse zu Clustern lässt sich nach [23] wie folgt definieren:

$$N_\epsilon(obs_i) = \{obs_j \in obs \mid d_{ij} \leq \epsilon_i \wedge d_{ij} \leq \epsilon_j\} \quad (1)$$

wobei  $d_{ij}$  die Distanz zwischen dem Hindernis  $i$  und dem Hindernis  $j$  im Straßenennetz repräsentiert. Die Erweiterung zeigt sich in der zweiten Bedingung und der Indexierung des  $\epsilon$ -Parameters. Das exemplarische Ergebnisse eines DBSCAN's bzw. ML-DBSCAN's ist in Bild 5 links ersichtlich.

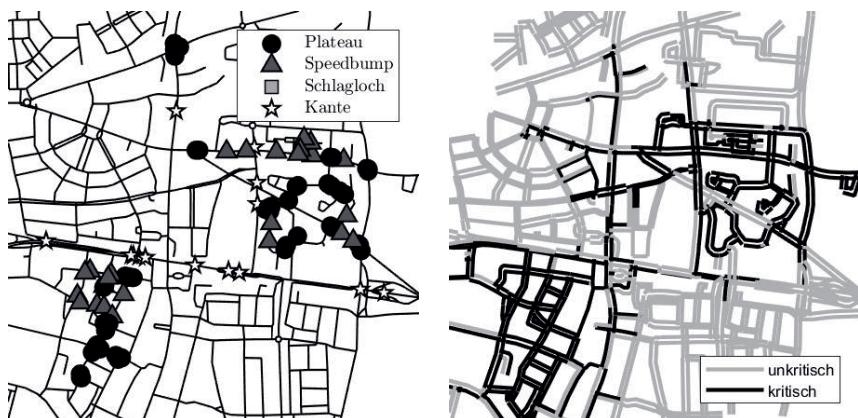


Bild 5: Ergebnis Clustering (links) und Option einer Hindernisüberfahrt innerhalb der nächsten 40 Sekunden (rechts)

Anhand von Bild 5 links ist zu erkennen, dass sich in den einzelnen Stadtgebieten verschiedene Cluster bilden, in denen die Dichte von normalen und kritischen Einzelhindernissen entsprechend hoch ist. Zusätzlich sind Hindernisse ersichtlich, welche keinem Cluster zugewiesen sind, sogenannte Noise. In diesen Fällen ist die zulässige Wegstrecke zu den ermittelten Clustern zu hoch bzw. die Eventdichte in Kombination mit der Straßentopologie zu gering, sodass die Wahrscheinlichkeit einer mehrfachen Überfahrt von Hindernissen in absehbarer Zeit zu gering ist und eine situationsgebundene Niveaulagenänderung zu bevorzugen ist.

Den Clustern müssen im Folgenden noch die zugehörigen Straßensegmente zugeordnet werden. Abhängig vom Anwendungsfall können verschiedene Verfahren genutzt werden. Neben dem geobasierten Geofencing oder Isolines sind worst und best case Szenarien oder die wahrscheinlichsten Routen für die Überfahrt eines relevanten Hindernisses innerhalb einer vorgegebenen Fahrtzeit möglich. Im betrachteten Beispiel für ein worst case Szenario werden ausgehend von der Lage der Hindernisse sowie einer beliebigen Fahrzeugposition die Routen

zu den umliegenden Hindernissen berechnet. Unterschreitet eine dieser Routen eine minimale bzw. maximale Fahrzeit, wird dieses Straßensegment als kritisch markiert, sodass ein quasi-statischer Kartenlayer erzeugt werden kann, siehe Bild 5 rechts. Diese Information kann anschließend bei der Fahrerwunscherkennung, siehe Abschnitt 5, im Fahrzeug genutzt werden, um relevante Gebiete für die Niveauanhebung der Fahrzeugkarosserie zu bestimmen. Befindet sich das Fahrzeug innerhalb eines Bereiches bzw. auf einem kritischen Straßensegment, bleibt die Fahrzeugtrimmlage angepasst. Die genaue Position der Einzelhindernisse muss dabei im Fahrzeug nicht mehr bekannt sein, die Niveauregulierung kann alleine auf der zusätzlich gewonnenen Cloud-Information geregelt werden.

## 7. Zusammenfassung und Ausblick

Der vorliegende Beitrag stellt ein Konzept eines „intelligenten Fahrwerks“ auf Basis von Cloud-Daten und fahrzeugspezifischen Informationen vor. Dabei liegt der Schwerpunkt auf der Generierung von neuen fahrwerksrelevanten Umfeldinformationen in der Cloud. Es wurde gezeigt, dass mit Hilfe von georeferenzierten Einzelhindernisdetections und erkannten Aufsetzvorgängen des Fahrzeugs in alltäglichen Fahrsituationen relevante Gebiete für die Fahrzeugtrimmlage im Backend aggregiert werden können. Dabei ließ sich eine effiziente Umsetzung in der Cloud herleiten, welche eine ressourcenaufwendige Implementierung im Fahrzeug vermeidet. Die gewonnenen Informationen werden im Anschluss in jedem Fahrzeug mit Hilfe der bereitgestellten digitalen Straßenzustandskarte von den präadaptiven Regelstrategien genutzt, um den Fahrkomfort und die Niveaulage zu optimieren und ein Aufsetzen zu vermeiden. Anhand der in diesem Beitrag generierten Schwarmdaten lassen sich für die Zukunft noch weitere Use Cases ableiten:

- Auf Grundlage der Straßenzustands- und Aufsetzinformationen kann eine individuelle Routenplanung des Navigationssystems erfolgen – „komfortabelste Route“.
- Auf Basis der Straßenzustände und Aufsetzvorgänge können die Bauteilbelastungen des Fahrwerks analysiert und für zukünftige Fahrzeugprojekte optimiert werden.
- Die Wartungsintervalle des Fahrzeugs können durch Auswertung der unterschiedlichen Straßeneinflüsse und Aufsetzvorgänge adaptiert und die Ausfallwahrscheinlichkeit von einzelnen Bauteilen reduziert werden – „Predictive Maintenance“.

## Literatur

- [1] Yamamoto, M. ; Hashiguchi, M. ; Nakagawa, S. : *Chassis, Control Systems and Equipment*, Journal of Society of Automotive Engineers of Japan, Vol. 67-69, 2013-2015.
- [2] Reif, K. : *Bosch Autoelektrik und Autoelektronik*, 6. Auflage, Bosch Fachinformation Automobil, Vieweg+Teubner Verlag, 2011.
- [3] Schiergl, A. : Verfahren zum Betreiben eines Antriebsstrangs eines Kraftfahrzeugs mit Freilauf-Motor-Aus-Funktion, sowie Steuergerät und Kraftfahrzeug, Offenlegungsschrift DE102 012 008 632A1, 2013.
- [4] Schütz, T. : *Verbesserte Aerodynamik des Audi Q3 und Q5*, Haus der Technik, 10. Tagung: Fahrzeug-Aerodynamik „Neue Chancen und Perspektiven für die Kraftfahrzeug-aerodynamik durch CO2-Gesetzgebung und Energiewende“, München, 2012.
- [5] Noll, A. ; Ament, C. : Konzeption und Entwicklung eines Preview-Systems zur Verbesserung der Komforteigenschaften und der Reichweiteffizienz eines Fahrzeugs mit geregelten Vertikaldynamiksystemen auf Basis von Backend-Daten, 32. VDI/VW-Gemeinschaftstagung: Fahrerassistenzsysteme und automatisiertes Fahren, Wolfsburg, 8.-9. November 2016.
- [6] Noll, A. ; Ament, C. : *Straßenklassifizierung und Einzelhindernisdetektion für cloudbasierte vertikale Fahrwerksfunktionen*, 17. Internationale VDI-Tagung Reifen-Fahrwerk-Fahrbahn, Hannover, 25.-26. Oktober 2017.
- [7] Noll, A. ; Ament, C. : *Potenzialanalyse prädiktiver Streckendaten zur Komfortsteigerung von Fahrzeugen mit geregelten Vertikaldynamiksystemen*, 8. VDI/VDE-Fachtagung AUTOREG 2017: Automatisiertes Fahren und vernetzte Mobilität, Berlin, 5.-6. Juli 2017.
- [8] Noll, A.: Konzeption und Entwicklung eines Preview-Systems durch Backend-Daten zur Verbesserung der Komforteigenschaften eines Fahrzeugs mit geregelten Vertikaldynamiksystemen, Universität Augsburg, Diss., in Druck.
- [9] Noll, A. ; Schwarz, R. ; Reitze, D. : *Intelligentes Fahrwerk – Aus Situationen lernen*, 34. VDI/VW-Gemeinschaftstagung: Fahrerassistenzsysteme und automatisiertes Fahren 2018, Wolfsburg, 7.-8. November 2018.
- [10] Li, Z. ; Kolmanovsky, I. V. ; Atkins, E. M. ; Lu, J. ; Filev, D. P. ; Bai, Y. : *Road Disturbance Estimation and Cloud-Aided Comfort-Based Route Planning*, IEEE Transactions on Cybernetics PP (2016), Nr. 99, S. 1-13.
- [11] Li, Z. : *Developments in Estimation and Control for Cloud-Enabled Automotive Vehicles*, University of Michigan, Diss., 2016.

- [12] Sugai, H. ; Buma, S. ; Kanda, R. ; Yoshioka, K. ; Hasegawa, M. : *Preview Ride Comfort Control for Electric Active Suspension*, In: Proceedings of the FISITA 2012 World Automotive Congress, SAE-China, Springer Berlin Heidelberg, 2013, S. 147-161.
- [13] Noll, A. ; Ament, C. : Accuracy and Robustness of Road Observers with Uncertainties for Reconstruction of the Road Elevation Profile, IEEE Intelligent Vehicles Symposium, Göteborg (Schweden), 2016.
- [14] ISO 8608, *Mechanical Vibration - Road Surface Profiles - Reporting of Measured Data*, International Organization for Standardization, ISO 8608:1995(E), 1995.
- [15] Mitschke, M. ; Wallentowitz, H. : *Dynamik der Kraftfahrzeuge*. 5. Aufl. Springer Vieweg, 2014 (VDI-Buch).
- [16] Zeller, P. : Handbuch Fahrzeugakustik: Grundlagen, Auslegung, Berechnung, Versuch; mit 43 Tabellen. 2. Aufl. Vieweg + Teubner, 2012 (ATZ-MTZ Fachbuch).
- [17] Sauter, M. : From GSM to LTE-Advanced: An Introduction to Mobile Networks and Mobile Broadband. Wiley, 2014.
- [18] White, C. E. ; Bernstein, D. ; Kornhauser, A. L.: *Some map matching algorithms for personal navigation assistants*. In: Transportation research part c: emerging technologies 8, 2000, Nr. 1, S. 91-108.
- [19] Berkhin, P. : *A Survey of Clustering Data Mining Techniques*. In: Grouping Multidimensional Data. Springer-Verlag Berlin Heidelberg, 2006, S. 25-71.
- [20] Engel, P. ; Balkema, J. ; Varchmin, A. : Verfahren und Anordnung zum Bestimmen eines am ehesten wahrscheinlichen Fahrpfads eines Fahrzeugs, Offenlegungsschrift, DE102011078946A1, 2013.
- [21] Haug, M. ; Moennich, J. ; Schaaf, G. : *Verfahren zum Bestimmen eines am ehesten wahrscheinlichen Fahrpfads*, Offenlegungsschrift, DE102009028299A1, 2011.
- [22] Ester, M. ; Kriegel, H.-P. ; Sander, J. ; Xu, X. : *A density-based algorithm for discovering clusters in large spatial databases with noise*, In: Kdd, vol. 96, 1996, S. 226-231.
- [23] Panahandeh, G. ; Åkerblom, N. : *Clustering driving destinations using a modified dbscan algorithm with locally-defined map-based thresholds*, In: Computational Methods and Models for Transport: New Challenges for the Greening of Transport Systems, Springer International Publishing, 2018, S. 97-103.

# Regelung eines redundant aktuierten Steer-by-Wire-Systems

## Control of redundant actuated Steer-by-Wire-Systems

**Volker Ewald, Prof. Ulrich Konigorski,**

Regelungstechnik und Mechatronik, Technische Universität Darmstadt

### Zusammenfassung

Im Rahmen des autonomen Fahrens gewinnen Steer-by-Wire (SbW) Systeme wieder an Bedeutung, da ein permanent mitdrehendes Lenkrad im Fahrzeug unerwünscht ist. Zudem müssen bei autonomen Fahrzeugen Redundanzen an der Fahrzeuglenkung vorgesehen werden, die bis heute als Hemmnis für SbW-Systeme galten. In diesem Beitrag wird ein Modell eines doppelt aktuierten SbW-Systems vorgestellt, bei dem die Aktoren der Lenkung elastisch miteinander verbunden sind. Anschließend wird das Modell vereinfacht. Ein Regelungskonzept für redundant aktuierte SbW-Systeme wird vorgestellt. Durch den Einsatz eines unterlagerten Drehzahlreglers wird durch Verkopplung die Systemordnung des redundanten Systems auf die eines Systems ohne Redundanz reduziert. Mittels eines algebraisch ausgelegten Model-Matching-Reglers wird das unterlagert geregelte System auf die Dynamik eines generischen Lenkungsmodells geregelt. Abschließend werden die Systemeigenschaften des geregelten Systems analysiert. Hierbei kann eine hohe Übereinstimmung zwischen dem geregelten System und dem Referenzsystem nachgewiesen werden. Des Weiteren wird die Passivität des geregelten Systems nachgewiesen, so dass dessen Stabilität bei der Ankopplung an eine passive Umgebung sichergestellt ist.

### 1. Einleitung

Seit den 1970er Jahren wird die X-by-Wire-Technologie eingesetzt [1]. So war die Concorde das erste Flugzeug, das mit einem Fly-by-Wire-System ausgestattet wurde. In der Automobilindustrie hat sich Drive-by-Wire heute am Markt durchgesetzt und ermöglicht ein gezieltes Anpassen der Parameter des Fahrzeugantriebs unter Berücksichtigung der fahrdynamischen Gesamtsituation des Fahrzeugs. Weitere X-by-Wire-Konzepte sind im Kraftfahrzeug in Serie nicht zu finden. So werden zwar diverse Prototypen und Sonderfahrzeuge mit Steer- oder Brake-by-Wire-Konzepten ausgestattet, jedoch haben sich die Konzepte bisher am Markt aufgrund der hohen Anforderungen an ausfallsichere Systeme nicht durchsetzen können. Dies wird sich jedoch in den nächsten Jahren ändern, weil durch die Entwicklung des autonomen

Fahrens ausfallsichere und somit redundante Lenksysteme in jedem Fahrzeug vorgesehen werden müssen [2]. Des Weiteren ist ein sich drehendes Lenkrad während der Fahrt eines autonom fahrenden Fahrzeugs für den Fahrer störend und kann bei hochdynamischen Ausweichmanövern des Fahrzeugs gefährlich für den Fahrer sein [3]. Ein drehendes Lenkrad in einem autonomen Fahrmodus würde sich aufgrund der Systemarchitektur bei SbW-Systemen unterbinden lassen.

Im Rahmen dieses Beitrags wird zunächst ein Modell eines überaktuierten SbW-Systems vorgestellt und vereinfacht. Anschließend wird eine unterlagerte Drehzahlregelung entworfen, welche die redundanten Aktoren synchronisiert und somit die Ordnung der unterlagert geregelten Strecke auf die des Zielsystems reduziert [4, 5]. Für die unterlagert geregelte Strecke wird ein Regler entworfen, der eine hohe Modellübereinstimmung zwischen der Strecke und einem Referenzmodell erreicht [6]. Besonders wird dabei auf die Robustheit der Regelung geachtet, welche mittels der Passivität des Systems untersucht wird [7].

## 2. Modellbildung

In diesem Abschnitt wird die Modellierung des SbW-Systems vorgestellt. Die Lenkungseinheit des Modells besteht aus zwei parallel geschalteten EPS-Systemen mit achsparallelen Antrieben (EPS APA Type) ohne Lenksäule [8, 9]. Die Lenkradeinheit besteht aus einer Welle, auf der sich ein Antrieb sowie ein Lenkrad befinden. Somit ergibt sich keine Nachgiebigkeit im Teilmodell Lenkrad. Die sich so ergebenden mechanischen Schaltbilder werden in Bild 1 dargestellt. Die Parameter des Modells wurden in [8] ermittelt und sind in Tabelle 1 beschrieben. Die Zustandsgrößen sowie Ein- und Ausgangsgrößen des mechanischen Modells sind in Tabelle 2 hinterlegt.

Bei der Modellbildung der EPS APA Type wird die Dynamik des Zahnriementriebs und des Kugelumlaufgetriebes, welche die rotatorische Bewegung der Motoren in eine translatorische Bewegung der Zahnstange übersetzen, mit der Dämpfung  $d_K$ , der Steifigkeit  $k_K$ , und zum Teil mit der Massenträgheit  $J_{A,S}$  berücksichtigt. Die Parameter  $d_K$  und  $k_K$  bestehen jedoch ausschließlich aus der Steifigkeit und Dämpfung des Kugelumlaufgetriebes, da der Zahnriementrieb gegenüber dem Kugelumlaufgetriebe als steif angesehen werden kann. Die Trägheit der Kugelumlaufgetriebe kann somit der Massenträgheit der Aktoren  $J_{A,S}$  zugeschlagen werden [8].

Aus dem mechanischen Schaltbild aus Bild 1 wird das Zustandsraummodell

$$\dot{\mathbf{x}}_{SW} = \mathbf{A}_{SW} \mathbf{x}_{SW} + \mathbf{B}_{SW} \mathbf{u}_{SW}, \quad \mathbf{y}_{SW} = \mathbf{C}_{SW} \mathbf{x}_{SW} \quad (1)$$

für das Lenkrad mit  $x_{SW} = \begin{bmatrix} \varphi_{SW} \\ \dot{\varphi}_{SW} \end{bmatrix}$ ,  $u_{SW} = \begin{bmatrix} M_{Drv} \\ M_{A,SW} \end{bmatrix}$ ,  $A_{SW} = \begin{bmatrix} 0 & 1 \\ 0 & -\frac{1}{J_{SW}} \end{bmatrix}$ ,  $B_{SW} = \begin{bmatrix} 0 & 0 \\ \frac{1}{J_{SW}} & \frac{1}{J_{SW}} \end{bmatrix}$  und  $C_{SW} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$  aufgestellt.

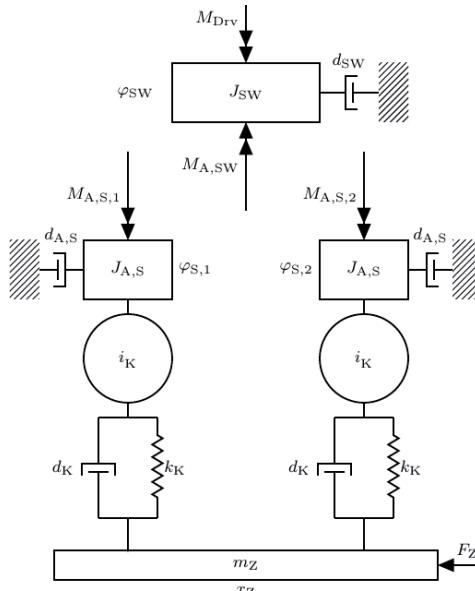


Tabelle 1: Parameter des mechanischen Lenkungsmodells nach [8]

Parameter	Wert	Einheit
$J_{SW}$	$5,19 \cdot 10^{-2}$	$\text{kgm}^2$
$d_{SW}$	$1,25 \cdot 10^{-1}$	$\text{Nms/rad}$
$J_{A,S}$	$4,08 \cdot 10^{-4}$	$\text{kgm}^2$
$d_{A,S}$	$1,35 \cdot 10^{-3}$	$\text{Nms/rad}$
$i_K$	$2,56 \cdot 10^3$	$\text{rad/m}$
$k_K$	$1,62 \cdot 10^7$	$\text{N/m}$
$d_K$	$2,88 \cdot 10^4$	$\text{Ns/m}$
$m_Z$	4,83	kg

Bild 1: Aufbau SbW

Tabelle 2: Eingänge, Ausgänge und Zustandsgrößen des mechanischen Modells

Parameter	Bedeutung	Einheit
$M_{Drv}$	Drehmoment Fahrer auf Lenkrad	Nm
$M_{A,SW}$	Drehmoment Aktor auf Lenkrad	Nm
$\varphi_{SW}$	Winkel Lenkrad	rad
$F_Z$	externe Zahnstangenkraft	N
$M_{A,S,1}$	Drehmoment Lenkungsaktor 1	Nm
$M_{A,S,2}$	Drehmoment Lenkungsaktor 2	Nm
$\varphi_{S,1}$	Winkel Lenkungsaktor 1	rad
$\varphi_{S,2}$	Winkel Lenkungsaktor 2	rad
$x_Z$	Position Zahnstange	m

Aus Bild 1 ergibt sich auch das Zustandsraummodell der Lenkung

$$\dot{\mathbf{x}}_{S,3\text{DoF}} = \mathbf{A}_{S,3\text{DoF}} \mathbf{x}_{S,3\text{DoF}} + \mathbf{B}_{S,3\text{DoF}} \mathbf{u}_{S,3\text{DoF}}$$

$$\begin{bmatrix} \dot{\varphi}_{S,1} \\ \dot{\varphi}_{S,1} \\ \dot{x}_Z \\ \dot{x}_Z \\ \dot{\varphi}_{S,2} \\ \dot{\varphi}_{S,2} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ -\frac{k_K}{J_{A,S} \cdot i_K^2} & -\frac{d_{A,S}}{J_{A,S}} - \frac{d_K}{J_{A,S} \cdot i_K^2} & \frac{k_K}{J_{A,S} \cdot i_K} & \frac{d_K}{J_{A,S} \cdot i_K} & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ \frac{k_K}{2 \cdot m_Z \cdot i_K} & \frac{d_K}{2 \cdot m_Z \cdot i_K} & -\frac{k_K}{m_Z} & -\frac{d_K}{m_Z} & \frac{k_K}{2 \cdot m_Z \cdot i_K} & \frac{d_K}{2 \cdot m_Z \cdot i_K} \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & \frac{k_K}{J_{A,S} \cdot i_K} & \frac{d_K}{J_{A,S} \cdot i_K} & -\frac{k_K}{J_{A,S} \cdot i_K^2} & -\frac{d_{A,S}}{J_{A,S}} - \frac{d_K}{J_{A,S} \cdot i_K^2} \end{bmatrix} \quad (2)$$

$$\begin{bmatrix} \varphi_{S,1} \\ \dot{\varphi}_{S,1} \\ x_Z \\ \dot{x}_Z \\ \varphi_{S,2} \\ \dot{\varphi}_{S,2} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ \frac{1}{J_{A,S}} & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \frac{1}{m_Z} \\ 0 & 0 & 0 \\ 0 & \frac{1}{J_{A,S}} & 0 \end{bmatrix} \begin{bmatrix} M_{A,S,1} \\ M_{A,S,2} \\ F_Z \end{bmatrix} \quad \text{und } \mathbf{y} = \mathbf{C}_{S,3\text{DoF}} \mathbf{x}_{S,3\text{DoF}} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \varphi_{S,1} \\ \dot{\varphi}_{S,1} \\ x_Z \\ \dot{x}_Z \\ \varphi_{S,2} \\ \dot{\varphi}_{S,2} \end{bmatrix}.$$

Die Position der Zahnstange ist nicht messbar, weswegen  $\mathbf{C}_{S,3\text{DoF}}$ , nicht der Einheitsmatrix entspricht.

Die Eigenwerte des Systems liegen bei  $\lambda_{S,3\text{DoF}} = [0 \quad -3,3 \quad -7,04 \pm 77,5i \quad -626,7 \quad -5345]^T$ . Die schnellen Eigenwerte  $-626,7$  und  $-5345$  resultieren aus der geringen Massenträgheit der Zahnstange gegenüber den Lenkungsaktoren ( $J_{A,S} \gg m_Z/i_K^2$ ). Dies lässt vermuten, dass diese beiden Eigenwerte nur einen geringen Einfluss auf die Dynamik des Systems haben. Da zudem die Zahnstangenposition  $x_Z$  nicht messbar ist, wird das um diesen Freiheitsgrad reduzierte Zustandsraummodell

$$\dot{\mathbf{x}}_S = \mathbf{A}_S \mathbf{x}_S + \mathbf{B}_S \mathbf{u}_S \quad (3)$$

$$\text{mit } \mathbf{x}_S = \begin{bmatrix} \varphi_{S,1} \\ \dot{\varphi}_{S,1} \\ \varphi_{S,2} \\ \dot{\varphi}_{S,2} \end{bmatrix}, \mathbf{u}_S = \begin{bmatrix} M_{A,S,1} \\ M_{A,S,2} \\ F_Z \end{bmatrix}, \mathbf{A}_S = \begin{bmatrix} 0 & 1 & 0 & 0 \\ -\frac{k_K}{2J_{A,S} \cdot i_K^2} & -\frac{d_{A,S} + \frac{d_K}{2 \cdot m_Z \cdot i_K^2}}{J_{A,S}} & \frac{k_K}{2J_{A,S} \cdot i_K^2} & \frac{d_K}{2J_{A,S} \cdot i_K^2} \\ 0 & 0 & 0 & 1 \\ \frac{k_K}{2J_{A,S} \cdot i_K^2} & \frac{d_K}{2J_{A,S} \cdot i_K^2} & -\frac{k_K}{2J_{A,S} \cdot i_K^2} & -\frac{d_{A,S} + \frac{d_K}{2 \cdot m_Z \cdot i_K^2}}{J_{A,S}} \end{bmatrix} \quad \text{und}$$

$$\mathbf{B}_S = \begin{bmatrix} 0 & 1 & 0 \\ \frac{1}{J_{A,S}} & 0 & \frac{1}{J_{A,S} \cdot i_K} \\ 0 & 0 & 0 \\ 0 & \frac{1}{J_{A,S}} & \frac{1}{J_{A,S} \cdot i_K} \end{bmatrix}$$

betrachtet, bei dem die Zahnstange als masselos angenommen wird ( $m_Z = 0\text{kg}$ ) und somit die beiden schnellsten Eigenwerte vernachlässigt werden [5]. Für das System gilt  $y_S = x_S$ , weil alle Zustände gemessen werden.

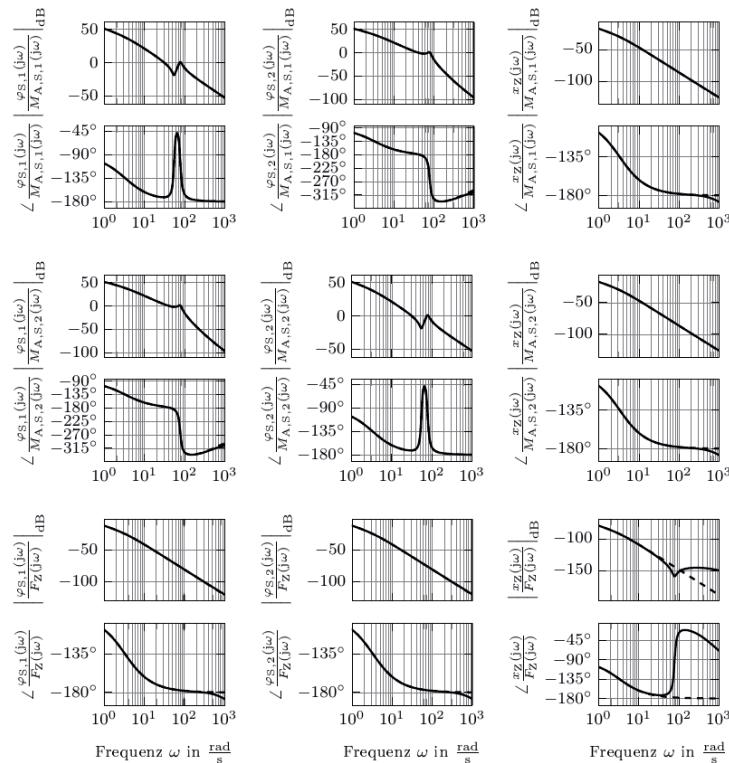


Bild 2: Bode-Diagramm Vergleich zwischen Modell mit drei mechanischen Freiheitsgraden (3DoF, durchgezogen) gegenüber zwei mechanischen Freiheitsgraden (2DoF, gestrichelt)

In Bild 2 ist zu erkennen, dass der Fehler durch die Vernachlässigung von  $m_Z$  bezüglich der Amplitude der Zahnstangenposition  $x_Z$  erst bei höheren Frequenzen in Erscheinung tritt. Bezuglich der Amplitude von  $\varphi_{S,1}$  und  $\varphi_{S,2}$  treten Abweichungen im abgebildeten Frequenzbereich nicht auf. Da der lenkungsdynamisch relevante Frequenzbereich zwischen  $0\text{Hz} < f < 30\text{Hz}$  liegt, kann das Modell daher um einen mechanischen Freiheitsgrad reduziert werden [10].

### 3. Regelung

In diesem Abschnitt wird die Regelung des SbW-Systems vorgestellt. Diese besteht aus zwei unterlagerten Drehzahlreglern, sowie einem Model-Matching-Regler. Dem Model-Matching-Regler wird ein lineares Referenzsystem vorgegeben, welches das Solverhalten der Lenkung abbildet. Der Aufbau des sich so ergebenden Systems ist in Bild 3 dargestellt.

Durch die unterlagerten Drehzahlregler werden zum einen die redundanten Aktoren synchronisiert und zum anderen Modellfehler und Nichtlinearitäten ausgeregelt, während der Model-Matching-Regler für die Verkopplung der Teilsysteme und somit mechanisch gesehen für die Nachbildung der Lenksäule verantwortlich ist. Die unterlagerten Drehzahlregelungen werden wesentlich schneller als der überlagerte Model-Matching-Regler und somit schneller als das Referenzsystems ausgelegt.

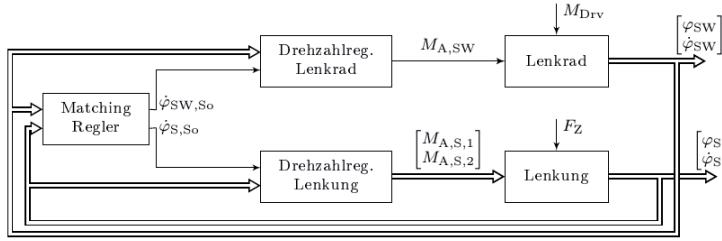


Bild 3: Reglerstruktur

Die Auslegung der Drehzahlregelung für das Lenkrad wird über Polplatzierung vorgenommen. Da es sich um ein Single-Input-Single-Output-System (SISO) handelt, wird auf eine Herleitung verzichtet und auf die entsprechende Literatur verwiesen [11]. Mit einem P-Regler und einem Vorfilter mit dem Regelgesetz

$$M_{A,SW} = k_{\phi,SW} \cdot \dot{\varphi}_{SW} + v_{\phi,SW} \cdot \dot{\varphi}_{SW,So} = -0,3945 \cdot \dot{\varphi}_{SW} + 0,519 \cdot \dot{\varphi}_{SW,So} \quad (4)$$

wird der Eigenwert des Lenkrads auf -10 gelegt und die stationäre Genauigkeit sichergestellt, sofern keine Störung am Lenkrad vorliegt.

Die Drehzahlregelung des Lenksystems gestaltet sich aufwendiger, weil beide Aktoren elastisch verbunden sind. Um ein Verspannen und somit Schwingen der Aktoren gegeneinander zu vermeiden, wird eine Verkopplungsregelung mittels Vollständiger Modaler Synthese eingesetzt [11]. Diese Regelung hat den Vorteil, dass die Systemordnung auf die eines Systems ohne Redundanz reduziert wird und somit die Drehzahl und Position eines Aktors für den überlagerten Regler unsteuerbar gemacht werden [5].

Als Verkopplungsbedingung wird  $\varphi_{S,1} - \varphi_{S,2} = 0$  festgelegt. Die Eigenwerte des Systems werden auf  $\lambda_{\dot{\varphi}_{S,G}} = [0 \ -15 \ -85 \ -90]^T$  gelegt. Der Eigenwert in 0 stellt sicher, dass die Drehzahl und nicht die Position die Führungsgröße des geregelten Systems ist. Der zweite Eigenwert in  $-15$  gibt dem verkoppelten drehzahlgeregelten System die Dynamik vor. Die beiden restlichen Eigenwerte in  $-85$  und  $-90$  werden für den überlagerten Model-Matching-Regler unsteuerbar gemacht und ausschließlich durch Störungen auf das System angeregt [12]. Das Regelgesetz

$$\begin{bmatrix} M_{A,S,1} \\ M_{A,S,2} \end{bmatrix} = \mathbf{K}_{\dot{\varphi}_S} \mathbf{x}_S + \mathbf{v}_S \dot{\varphi}_{S,S0} \quad (5)$$

$$= 10^{-3} \begin{bmatrix} -324,6 & -35,21 & 324,6 & 30,44 \\ 324,6 & 30,44 & -324,6 & 35,21 \end{bmatrix} \mathbf{x}_S + \begin{bmatrix} 6,11 \\ 6,11 \end{bmatrix} \dot{\varphi}_{S,S0}$$

beschreibt den Verkopplungsregler für das System (3).

Werden die Drehzahlregler (4) und (5) in (1) und (3) eingesetzt und die beiden unterlagert geregelten Teilsysteme zu einem System zusammengefasst, ergibt sich

$$\dot{\mathbf{x}}_{\text{Sys}} = \mathbf{A}_{\text{Sys}} \mathbf{x}_{\text{Sys}} + \mathbf{B}_{\text{Sys},1} \mathbf{u}_{\text{Sys},1} + \mathbf{B}_{\text{Sys},2} \mathbf{u}_{\text{Sys},2} \quad (6)$$

$$\begin{bmatrix} \dot{\varphi}_{SW} \\ \dot{\varphi}_{SW} \\ \dot{\varphi}_{S,1} \\ \dot{\varphi}_{S,1} \\ \dot{\varphi}_{S,2} \\ \dot{\varphi}_{S,2} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & -10 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & -3825 & -95 & 3825 & 80 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 3825 & 80 & -3825 & -95 \end{bmatrix} \begin{bmatrix} \varphi_{SW} \\ \dot{\varphi}_{SW} \\ \varphi_{S,1} \\ \dot{\varphi}_{S,1} \\ \varphi_{S,2} \\ \dot{\varphi}_{S,2} \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 10 & 0 \\ 0 & 0 \\ 0 & 15 \\ 0 & 0 \\ 0 & 15 \end{bmatrix} \begin{bmatrix} \dot{\varphi}_{SW,So} \\ \dot{\varphi}_{S,So} \end{bmatrix}$$

$$+ \begin{bmatrix} 0 & 0 \\ 19,27 & 0 \\ 0 & 0 \\ 0 & 0,4797 \\ 0 & 0 \\ 0 & 0,4797 \end{bmatrix} \begin{bmatrix} M_{\text{Drv}} \\ F_Z \end{bmatrix}$$

als drehzahlgeregeltes Gesamtsystem.

Das Referenzsystem, an das dieses System angepasst werden soll, wird durch das Zustandsraummödell  $\dot{\mathbf{x}}_{\text{Re}} = \mathbf{A}_{\text{Re}} \mathbf{x}_{\text{Re}} + \mathbf{B}_{\text{Re}} \mathbf{u}_{\text{Re}}$  mit

$$\mathbf{x}_{\text{Re}} = \begin{bmatrix} \Delta_{\text{Re}} \\ \dot{\varphi}_{SW,\text{Re}} \\ \dot{x}_{Z,\text{Re}} \end{bmatrix}, \mathbf{u}_{\text{Re}} = \begin{bmatrix} M_{\text{Drv}} \\ F_Z \end{bmatrix}, \mathbf{A}_{\text{Re}} = \begin{bmatrix} 0 & 1 & -i_S \\ -\frac{k_{TB,\text{Re}}}{J_{SW,\text{Re}}} & -\frac{d_{TB,\text{Re}}+d_{SW,\text{Re}}}{J_{SW,\text{Re}}} & \frac{d_{TB,\text{Re}} i_S}{J_{SW,\text{Re}}} \\ \frac{k_{TB,\text{Re}} i_S}{m_{Z,\text{Re}}} & \frac{d_{TB,\text{Re}} i_S}{m_{Z,\text{Re}}} & -\frac{d_{TB,\text{Re}} i_S^2 + d_{Z,\text{Re}}}{m_{Z,\text{Re}}} \end{bmatrix} \text{ und} \quad (7)$$

$$\mathbf{B}_{\text{Re}} = \begin{bmatrix} 0 & 0 \\ \frac{1}{J_{SW,\text{Re}}} & 0 \\ 0 & \frac{1}{m_{Z,\text{Re}}} \end{bmatrix}$$

beschrieben. Der Zustandsvektor besteht aus der Drehzahl des Lenkrads  $\dot{\varphi}_{SW,Re}$ , der Zahntangengeschwindigkeit  $\dot{x}_{Z,Re}$ , sowie der Verdrehung des Drehstabs  $\Delta_{Re}$  bezogen auf die Lenksäule. Beliebige Zweimassenschwinger, deren Massenträgheitsmoment mit denen des zu regelnden Systems übereinstimmen, können dem System als Referenzmodell wie in Bild 4 dargestellt, vorgegeben werden. Für die freien Parameter wird auf Literaturwerte zurückgegriffen [1]. Die mechanischen Parameter sind in Tabelle 3 angegeben. Die Eigenwerte des Referenzsystems der Lenkung ergeben sich aus  $A_{Re}$  zu  $\lambda_{Re,1,2} = -1,36 \pm 50,44i$  und  $\lambda_{Re,3} = -0,026$ .

Aus Sicht der überlagerten Model-Matching-Regelung des Systems sind zwei Zustände aufgrund des Verkopplungsreglers über  $u_{Sys,1}$  nicht steuerbar. Bei alleiniger Betrachtung des Differenzwinkels ist der Absolutwinkel  $\varphi_{SW}$  nicht beobachtbar. Daher lässt sich das System aus (6) auf drei Zustände reduzieren. Als Zustandsvektor des reduzierten Systems wird  $x_{Sys,Red} =$

$$\begin{bmatrix} \varphi_{SW} - \frac{i_S}{l_K} \varphi_S & \dot{\varphi}_{SW} & \dot{\varphi}_{S,1} \end{bmatrix}^T \text{ gewählt. Somit ergibt sich für das zustandsreduzierte System}$$

$$\dot{x}_{Sys,Red} = A_{Sys,Red} x_{Sys,Red} + B_{Sys,Red,1} u_{Sys,1} + B_{Sys,Red,2} u_{Sys,2} \quad (8)$$

$$\begin{bmatrix} \dot{\Delta}_{Re} \\ \dot{\varphi}_{SW,Re} \\ \dot{\varphi}_{S,Re} \end{bmatrix} = \begin{bmatrix} 0 & 1 & -0,04912 \\ 0 & -10 & 0 \\ 0 & 0 & -15 \end{bmatrix} \begin{bmatrix} \Delta_{Re} \\ \dot{\varphi}_{SW} \\ \dot{\varphi}_S \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 10 & 0 \\ 0 & 15 \end{bmatrix} \begin{bmatrix} \dot{\varphi}_{SW,So} \\ \dot{\varphi}_{S,So} \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 19,27 & 0 \\ 0 & 0,4797 \end{bmatrix} \begin{bmatrix} M_{Drv} \\ F_Z \end{bmatrix}.$$

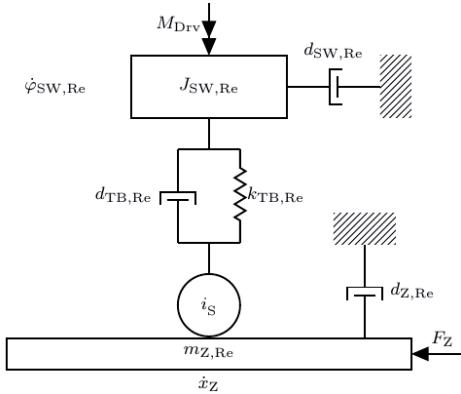


Bild 4: Aufbau Referenzsystem

Tabelle 3: Parameter des Referenzsystems

Parameter	Wert	Einheit
$J_{SW,Re}$	0,0519	$\text{kgm}^2$
$d_{SW,Re}$	0,01	$\text{Nms} / \text{rad}$
$d_{TB,Re}$	0,1146	$\text{Nms} / \text{rad}$
$k_{TB,Re}$	114,59	$\text{Nm} / \text{rad}$
$m_{Z,Re}$	5456,1	kg
$d_{Z,Re}$	0,01	$\text{Ns} / \text{m}$
$i_S$	125,66	$\text{rad} / \text{m}$

Die überlagerte Regelung wird mittels eines algebraischen Model-Matching-Ansatzes realisiert [6]. Für das Referenzsystem aus (7) wird eine Zustandstransformation mit

$$\mathbf{x}_{Re,T} = \begin{bmatrix} \Delta_{Re} \\ \dot{\phi}_{SW,Re} \\ \dot{\phi}_{S,Re} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & i_K \end{bmatrix} \begin{bmatrix} \Delta_{Re} \\ \dot{\phi}_{SW,Re} \\ \dot{x}_{Z,Re} \end{bmatrix}$$

vorgenommen, aus der sich das transformierte Referenzsystem  $\dot{\mathbf{x}}_{Re,T} = \mathbf{A}_{Re,T}\mathbf{x}_{Sys,Red} + \mathbf{B}_{Re,T}\mathbf{u}_{Re}$  ergibt. Dabei wird die Position der Zahnstange auf den Winkel des Lenkungsaktors transformiert, damit dieselben Systemzustände wie in (8) vorliegen.

Für die Systemmatrix des geregelten Systems gilt  $\mathbf{A}_G = \mathbf{A}_{Sys,Red} + \mathbf{B}_{Sys,Red,1}\mathbf{K}_{ma}$  und es soll  $\mathbf{A}_{Re,T} = \mathbf{A}_G$  gelten, also die Systemmatrix des geregelten Systems der des Referenzsystems entsprechen. Dann muss  $\mathbf{B}_{Sys,Red,1}\mathbf{K}_{ma} = \mathbf{A}_{Re,T} - \mathbf{A}_{Sys,Red}$

$$\begin{bmatrix} 0 & 0 \\ 10 & 0 \\ 0 & 15 \end{bmatrix} \mathbf{K}_{ma} = \begin{bmatrix} 0 & 1 & -0,0491 \\ -2207,9 & -2,4008 & 0,1084 \\ 6893,1 & 6,8937 & -0,3384 \end{bmatrix} - \begin{bmatrix} 0 & 1 & -0,0491 \\ 0 & -10 & 0 \\ 0 & 0 & -15 \end{bmatrix}$$

gelten. Durch die vorliegende Struktur der Matrizen ist diese Gleichung gemäß

$$\begin{aligned} \mathbf{K}_{ma} &= \mathbf{B}_{Sys,Red,1}^+ \cdot (\mathbf{A}_{Re,T} - \mathbf{A}_{Sys,Red}) \\ &= \begin{bmatrix} 0 & 0 \\ 10 & 0 \\ 0 & 15 \end{bmatrix}^+ \cdot \left( \begin{bmatrix} 0 & 1 & -0,0491 \\ -2207,9 & -2,4008 & 0,1084 \\ 6893,1 & 6,8937 & -0,3384 \end{bmatrix} - \begin{bmatrix} 0 & 1 & -0,0491 \\ 0 & -10 & 0 \\ 0 & 0 & -15 \end{bmatrix} \right) \\ &= \begin{bmatrix} -221,21 & 0,762 & 0,011 \\ 461,05 & 0,461 & 0,981 \end{bmatrix} \end{aligned}$$

analytisch lösbar.

Somit ergibt sich aus den zwei Teilreglern, Drehzahlregler und Model-Matching-Regler, ein Regelgesetz, das über

$$\begin{aligned} \begin{bmatrix} M_{A,SW} \\ M_{A,S,1} \\ M_{A,S,2} \end{bmatrix} \mathbf{K}_{ma} &= \begin{bmatrix} k_{\dot{\phi}_{SW}} & \mathbf{0} \\ \mathbf{0} & \mathbf{K}_{\dot{\phi}_S} \end{bmatrix} \begin{bmatrix} \dot{\phi}_{SW} \\ \mathbf{x}_S \end{bmatrix} + \begin{bmatrix} v_{\dot{\phi}_{SW}} & \mathbf{0} \\ \mathbf{0} & v_S \end{bmatrix} \mathbf{K}_{ma} \mathbf{x}_{Sys,Red} \\ &= \begin{bmatrix} -114,6 & 0,0004 & 5,63 & 0 & 0,006 & 0 \\ 2,812 & 0,0028 & -0,46 & 0,33 & -0,029 & 0,03 \\ 2,812 & 0,0028 & 0,19 & -0,33 & 0,036 & -0,04 \end{bmatrix} \begin{bmatrix} \dot{\phi}_{SW} \\ \dot{\phi}_{S,1} \\ \dot{\phi}_{S,2} \\ \dot{\phi}_{S,3} \\ \dot{\phi}_{S,4} \\ \dot{\phi}_{S,5} \end{bmatrix} \end{aligned}$$

beschrieben wird.

#### 4. Systemanalyse

In diesem Abschnitt werden die Systemeigenschaften des geregelten Systems analysiert. Hierbei wird die Stabilität des Systems über die Passivität und die Transparenz mittels der Differenz der Admittanz des geregelten und des Referenz-Systems untersucht.

Um die Übereinstimmung zwischen dem Wunschverhalten und dem Verhalten des geregelten Systems zu analysieren, wird die Admittanz des geregelten Systems mit der des Referenzsystems verglichen. In Bild 5 ist zu erkennen, dass die Frequenzgänge von der Zahnstangenkraft zur Lenkradgeschwindigkeit ( $\dot{\varphi}_{SW}(j\omega)/F_Z(j\omega)$ ) und vom Fahrerdrehmoment zur Zahnstangengeschwindigkeit ( $\dot{x}_Z(j\omega)/M_{Drv}(j\omega)$ ) für  $\omega < 900$  rad/s gut übereinstimmen. Der lenkungsdynamisch relevante Frequenzbereich liegt zwischen  $0$  rad/s  $< \omega < 190$  rad/s und wird somit gut durch das geregelte System dargestellt [10].

Im Frequenzgang von ( $\dot{x}_Z(j\omega)/F_Z(j\omega)$ ) aus Bild 5 wirken sich ab  $\omega > 50$  rad/s die Modellvereinfachungen aus, wie im Vergleich mit Bild 2 festgestellt werden kann. Allerdings ist der Übertragungspfad nicht relevant für die Informationsübertragung des Systems an den Fahrer.

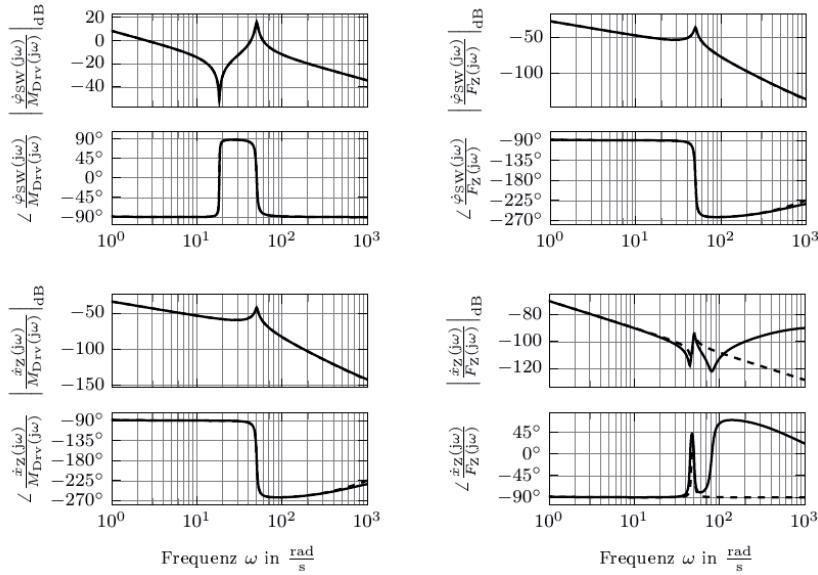


Bild 5: Bode-Diagramm Vergleich Referenzsystem (gestrichelt) und geregeltes System (durchgezogen)

Die Passivität eines Systems stellt die Stabilität des Gesamtsystems sicher, wenn dieses an weitere passive Systeme gekoppelt wird. Passivität kann über den Frequenzgang des Systems nachgewiesen werden. In Bild 5 ist zu sehen, dass sowohl das Referenzsystem als auch das geregelte System passiv sind. Das geregelte System ist passiv und die Stabilität des Gesamtsystems wird sichergestellt, da die Phase an den Toren des Zweitors nicht unter  $-90^\circ$  fällt

[7]. Die Voraussetzung, dass die angekoppelten Systeme passiv sind, stellt dabei keine Einschränkung dar, weil davon auszugehen ist, dass die Fahrzeugquerdynamik und der Fahrer passiv sind [6].

## 5. Ergebnisse

Im Rahmen dieses Beitrags wird das mechanische Modell eines doppelt aktuierten SbW-Systems vorgestellt. Die Modellbildung wird erläutert und eine Reduktion des Modells um einen mechanischen Freiheitsgrad vorgenommen.

Darauf folgend wird ein Regelungskonzept für SbW-Systeme vorgestellt, welches für redundant aktuierte Systeme geeignet ist, deren Aktoren verkoppelt sind. Dabei werden zwei Drehzahlregler, welche die Aktoren unterlagert regeln, entworfen und des Weiteren ein überlagerter Model-Matching-Regler, der die Dynamik des Systems auf die eines generischen Referenzsystems anpasst. Der Regler wird aus einer algebraischen Gleichung analytisch berechnet. Abschließend werden die Systemeigenschaften des geregelten Systems untersucht. Das geregelte System zeigt dasselbe Übertragungsverhalten wie das Referenzsystem für den lenkdynamisch relevanten Frequenzbereich. Zudem kann dem geregelten System Passivität nachgewiesen werden, was die Stabilität des Gesamtsystems sicherstellt.

## 6. Ausblick

Im nächsten Schritt muss eine weitere überlagerte Regelung entworfen werden, welche die Lenkungsfunktionen einer elektrischen Servolenkung für das SbW bereitstellt [1]. Dieses Regelungskonzept wird anschließend am Prüfstand des Fachgebiets implementiert.

Des Weiteren wurde im Rahmen dieser Arbeit der Freiheitsgrad, der sich aus der Überaktuierung des Systems ergibt, nicht weiter genutzt. Weitere Untersuchungen, z.B. die Möglichkeit, die Stellgrößen an der redundant aktuierten Lenkung gezielt aufzuteilen, sollen dazu noch erfolgen und umgesetzt werden.

## 7. Literaturangaben

- [1] Pfeffer, P. u. Harrer, M.: Lenkungshandbuch. Lenksysteme, Lenkgefühl, Fahrdynamik von Kraftfahrzeugen. Praxis ATZ/MTZ-Fachbuch. Wiesbaden: Vieweg+Teubner Verlag / Springer Fachmedien Wiesbaden GmbH Wiesbaden 2011
- [2] Winner, H., Isermann, R. u. Schürr, A. (Hrsg.): Steuerung und Regelung von Fahrzeugen und Motoren - AUTOREG 2004. Tagung Wiesloch, 2. und 3. März 2004. VDI-Berichte, 1828, Buch. Düsseldorf: VDI-Verlag 2004
- [3] Nexteer: Nexteer's Steering on Demand™ System – Nexteer, 2018. <https://www.nexteer.com/a-d-a-s-automated-driving/steering-on-demand/>, abgerufen am: 17.10.2018
- [4] Konigorski, U.: Regelung einer mechatronischen Kraftfahrzeuglenkung. TUContact 1999 (1999) 4
- [5] Keßler, P.: Einstellbare Verkopplungsregelung für ein Duplex-Aktorsystem einer achsparallelen elektrischen Servolenkung (EPS). Diagnose in mechatronischen Fahrzeugsystemen IX. Neue Verfahren für Test, Prüfung und Diagnose von E/E-Systemen im Kfz. Dresden: TUDpress Verlag der Wissenschaften Dresden 2015, S. 217–231
- [6] Odenthal, D., Bünte, T., Heitzer, H.-D. u. Eicker, C.: Übertragung des Lenkgefühls einer Servo-Lenkung auf Steer-by-Wire. Steer-by-wire Control Design for Achievement of Power Steering Like Performance. at - Automatisierungstechnik 51 (2003) 7-2003, S. 329–337
- [7] Colgate, J. E.: Robust impedance shaping telemanipulation. IEEE Transactions on Robotics and Automation 9 (1993) 4, S. 374–384
- [8] Beck, M. u. Keßler, P. (Hrsg.): Modelling and Identification of an axial parallel EPS System. IQPC 8th Annual Conference on Steering Systems Düsseldorf. 2014
- [9] Winner, H., Hakuli, S., Lotz, F. u. Singer, C.: Handbuch Fahrerassistenzsysteme. Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort. ATZ/MTZ-Fachbuch. Wiesbaden: Springer Vieweg 2015
- [10] Groll, M. von: Modifizierung von Nutz- und Störinformationen am Lenkrad durch elektromechanische Lenksysteme, Universität Duisburg-Essen Dissertation. Essen 2006
- [11] Föllinger, O.: Regelungstechnik. Einführung in die Methoden und ihre Anwendung. Berlin, Offenbach: VDE Verlag GmbH 2016
- [12] Konigorski, U.: Ausgangsgrößenverkopplung bei linearen Mehrgrößensystemen. at - Automatisierungstechnik 47 (1999) 4

# Model Predictive Control of an Active Roll Stabilization System

M. Sc. **Georgi Nareyko**, Dr.-Ing. **Thorsten Koch**,  
Prof. Dr.-Ing. **Ansgar Trächtler**, University of Paderborn

## Zusammenfassung

Im Rahmen dieses Beitrags wird die Auslegung der Optimierung mittels modellbasierter prädiktiver Regelung (MPC) zur Verbesserung der Fahrzeugwankdynamik bei fahrbahninduzierten Störanregungen vorgestellt. Zunächst wird die Formulierung der notwendigen Systemgleichungen der Fahrzeugvertikal- und Aktordynamik präsentiert. Die Drehzahl- und Momentenbeschränkungen bilden mit dem Gütekriterium das Optimierungsproblem. Mittels Minimierung anhand von Zielkriterien wird eine Fahrkomfortverbesserung erzielt. Ein besonderer Fokus liegt hierbei auf der Auswahl der bewerteten Frequenzbereiche, die signifikant zum Komfortempfinden beitragen. Simulationen mit zahlreichen Fahrmanövern bestätigen die Verbesserungsmöglichkeiten im Vergleich zu einer Referenzregelvariante. Das Ziel des Beitrags ist die Darstellung des Optimums zwischen Fahrkomfort und Leistungsaufnahme bei gegebener Charakteristik der Aktorik.

## Abstract

In this contribution, a model predictive control (MPC) is designed to optimize the vehicles' roll dynamics which is induced by road disturbances. Firstly, the system equations of the vehicle and actuator are presented. Secondly, the optimization problem is created and contains saturations of rotational speed and torque. After that, a solution is presented, by which the control quality function is minimized. A special focus is set on the selection of the evaluated frequency range which is most significant for ride comfort. Simulations of several road excitations confirm the improvement compared to a reference control variant. The target of this work is to present the optimum between ride comfort and power consumption with a specified actuator.

## 1. Electromechanical active roll control

Electromechanical active roll stabilization systems are used to enhance the spread between driving dynamics and ride comfort. There are numerous advantages compared to passive anti-roll bars. The roll stabilization system contains an actuator at the front and rear axle.

## 1.1 System setup and software partition

In contrary to a conventional roll control, the active roll control consists of a torsion bar spring which is separated in two halves with an actuator in between. Additionally, the total system requires sensors and a suitable signal processing so that every required signal is available for the control algorithm. Compared to the conventional variant, the functional advantages of the total system are:

- Increase of vehicles' subjective solidity by reduction of the roll angle
- Improvement of ride comfort by reduction of the so called roll copying
- Higher tire lateral forces potential
- Adjusted self-steering behavior towards neutral steering depending of the driving situation

There are several actuator concepts. Fig 1 shows the system components of an electromechanical active roll control with 48 V power supply which is used in series vehicles:

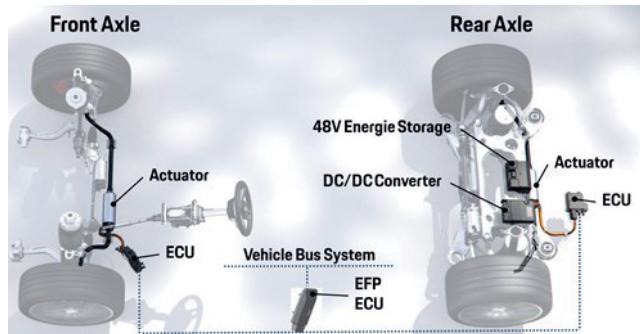


Fig. 1: System Components

The system is available in several vehicles of the Dr.-Ing. h.c. F. Porsche AG. Each axle contains an actuator with its own separated ECU. This constellation is a specialty which results from package restrictions in the axle concept. By that, the length of the stabilizer bar could be increased so that the stiffness is reduced which is a positive aspect to meet ride comfort requirements. The power supply with 48 V is rational due to the prevalence of this technology and resulting lower cross-section of the motor cables.

Regarding the signal processing, a central chassis ECU (*Elektronische Fahrwerkplattform, EFP*) provides signals in a specified quality for the structurally identical roll control ECUs (Fig.

2). Required signals such as ride height or wheel and body vertical acceleration signals are transformed, filtered and transmitted via CAN-connection.

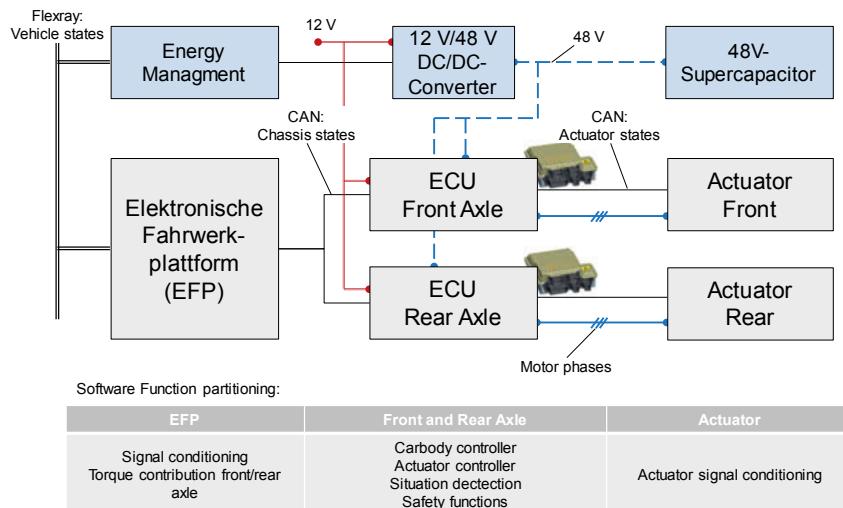


Fig. 2: ECU topology and software partition [1]

## 1.2 Actuator concept and force transmission into the car body

Both halves of the torsion bar are separated in the middle and connected to the actuator which is able to twist them relatively. As the roll bars are connected to the car body and their ends are attached by coupling rods to the wheel suspension, they are able to transfer equal forces between the left and right hand side of the vehicle although they are directed in opposite directions. The actuator consists of a 48 V brushless DC-Motor and a three stage planetary gear. With the high gear ratio the actuator is able to twist both torsion bar halves up to an angle of  $\pm 30^\circ$  which leads to an approximate torque of 1200 Nm. Further relevant motor- and gear-unit limits in the rotation speed and motor torque are shown in fig. 3.

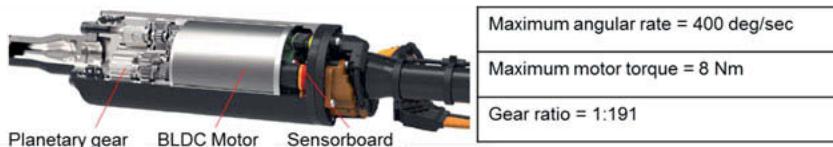


Fig. 3: Actuator Components

## 2. Model Design

Assuming a linear vertical car model, it contains seven degrees of freedom: body roll angle  $\varphi_a$ , every translational wheel travel  $z_{R,ij}$  and actuator angle  $\varphi_{Akt,i}$  at the front and rear axle. Model inputs are the control variables  $\varphi_{Akt,i,Set}$ . A model reduction has been already carried out so that further degrees of freedom such as body heave or pitch were eliminated.

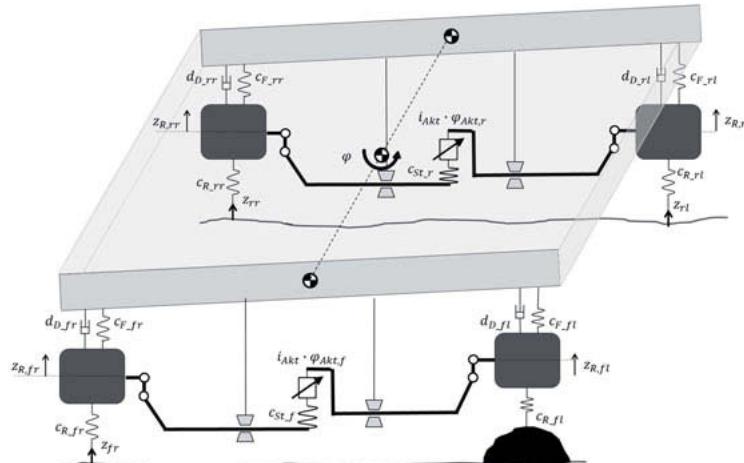


Fig. 4: System model of the car body and suspension with an active roll stabilization system

The defined system equations can be put together in a state space model as shown in equation (1).

$$\dot{\underline{x}}(t) = A\underline{x}(t) + B\underline{u}(t) + B_z\underline{z}(t) \quad (1)$$

$$\underline{y}(t) = C\underline{x}(t)$$

with

$$\underline{x} = [\varphi, z_{R,fl}, z_{R,fr}, z_{R,rl}, z_{R,rr}, \varphi_{Akt,r}, \varphi_{Akt,r}, \dot{\varphi}, \dot{z}_{R,fl}, \dot{z}_{R,fr}, \dot{z}_{R,rl}, \dot{z}_{R,rr}, \dot{\varphi}_{Akt,f}, \dot{\varphi}_{Akt,r}]^T$$

$$\underline{u} = [\varphi_{Akt,f,Set}, \varphi_{Akt,r,Set}]^T$$

$$\underline{z} = [z_{fl}, z_{fr}, z_{rl}, z_{rr}]^T$$

The tire is modeled with a spring stiffness, the car suspension is also depicted by a spring stiffness, a damper rate and the active roll stabilization force is induced by the actuator angle. Disturbance is caused by the road unevenness which is represented by  $z_{ij}$ . The dynamics of both actuators is approximated by a low bandwidth of filter second order with a base frequency of 10 Hz and a damping rate which originates the specification in fig. 3. Detailed equations of

motions were presented e.g. in [2]. To carry out a model predictive controller design we further assume the output  $\underline{y} = [\varphi, \dot{\varphi}, \ddot{\varphi}]$ . As  $\ddot{\varphi}$  is not a system state, it can easily be formulated as a linear combination of the other states. In the following the underscore will be omitted in order to simplify.

### 3. Model Predictive Control to increase the ride comfort

Common use cases of the MPC are trajectory control and control with changing operational points [3]. But there are also some publications which analyzed the implementation within the active chassis control with preview information [4], [5] and [6]. The biggest difficulty is the missing predictability of road disturbances so that the system behavior cannot be predicted with a large horizon and should be optimized with a high update rate. In [7], [8] and [9] this problem has been analyzed without preview information.

A new challenge occurs in the optimization of ride comfort. In contrast to a hydraulic active roll control [10] a thorough control concept is required as there is no hydraulic feedback. As a consequence every road disturbance force will be transmitted into the car body if there is no active compensating force at the actuator.

The actuator set angle  $\varphi_{Akt,i,Set}$  is the control variable to influence the compensating force  $F_{comp,i,Set} = i_k \cdot c_{St,i} \cdot \varphi_{Akt,i,Set}$  with  $i_k$  as a kinematics transmission value and  $c_{St,i}$  as a stiffness at the axle  $i$  which stands for front/rear axle, respectively. For the control design several targets should be regarded:

- The torsion angle should follow the excitation by the wheels and minimize the induced forces.
- The mean and maximum power consumption should be reduced.

As a goal conflict arises, an MPC could be used to minimize a control quality function which includes both targets. Moreover, the highly important actuator limits are included therein.

#### 3.1 Approach for design of the model predictive control

The usage of model predictive control requires the system model of the car which was shown in section 2. The equations were formulated in continuous state space and discretized subsequently as follows:

$$x_{k+1} = A \cdot x_k + B_u \cdot u_k + B_z \cdot z_k \quad (2)$$

$$y_k = C \cdot x_k$$

$$u_k = [\varphi_{Akt,f,Set,k}, \varphi_{Akt,r,Set,k}]^T, \quad z_k = [z_{fl,k}, z_{fr,k}, z_{rl,k}, z_{rr,k}]^T \quad (3)$$

It consists of  $u_k \in \mathbb{R}^m$ ,  $x_k \in \mathbb{R}^n$ ,  $z_k \in \mathbb{R}^p$  and  $y_k \in \mathbb{R}^r$ . The mathematical equation system is clearly not controllable by input  $u_k$ , obviously e.g. the wheel travel cannot be independently controlled by the set actuator angle. However, in the following research only the roll mode is significant. The optimization task with a prediction horizon of  $n_p$  steps is to minimize

$$\min_u J_k = \sum_{i=1}^{n_p} (y_{Ref,k+i} - C \cdot x_{k+i})^T \cdot Q \cdot (y_{Ref,k+i} - C \cdot x_{k+i}) + u_{k+i}^T \cdot R \cdot u_{k+i} \quad (4)$$

Nonlinear constraints form the second part of the optimization problem. Two limitations are considered, namely rotational speed ( $n_{min}, n_{max}$ ) and motor torque ( $m_{min}, m_{max}$ ) limits:

$$\text{s.t. } n_{min} < \begin{bmatrix} \dot{\varphi}_{Akt,f,k+i} \\ \dot{\varphi}_{Akt,r,k+i} \end{bmatrix} < n_{max} \quad (5)$$

$$m_{min} < M_\Theta \cdot \begin{bmatrix} \dot{\varphi}_{Akt,f,k+i} - \dot{\varphi}_{Akt,f,k+i-1} \\ \dot{\varphi}_{Akt,r,k+i} - \dot{\varphi}_{Akt,r,k+i-1} \end{bmatrix} - M_c \cdot \begin{bmatrix} \varphi_{f,k+i} \\ \varphi_{r,k+i} \end{bmatrix} < m_{max}$$

$$\text{with } M_\Theta = \frac{i_n \Theta}{t_s}, M_c = \frac{C_{St,i}}{i_n} \text{ and } i = 1, \dots, n_p$$

A particularity persists within the torque limitations, as this is initially not part of the system model. Therefore, a change of rotational speed  $\dot{\varphi}_{Akt,i}$  is translated into torque as the inertia moment and counter moment are known from the system equations [11]. A counter moment is necessary as both ends of the stabilizer bars are not freely movable. Therefore,  $\varphi_f$  and  $\varphi_r$  represent the stabilizer bar torsion which can be calculated separately.

Due to the amount of system states, state limitations and the unpredictable disturbances, the determination of optimal control variables  $u_k$  to minimize  $J_k$  is not simple. In [12] an efficient approach has been presented to approximate the actual system behavior with disturbances to a reference system behavior. The idea is revised to a structure which is shown in fig. 5

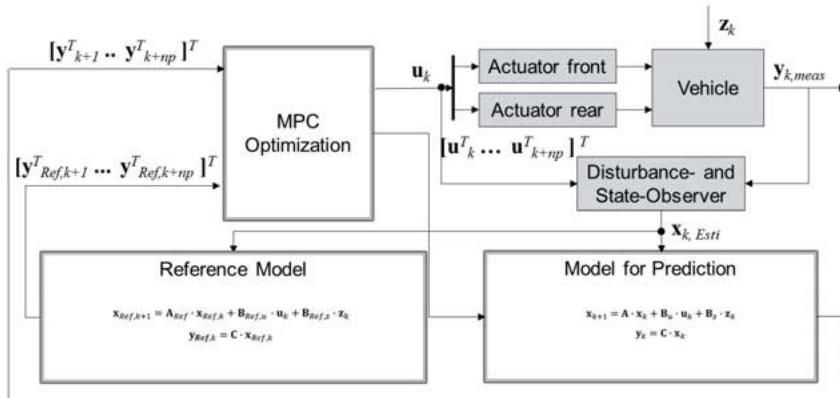


Fig. 5: MPC disturbance compensation with reference model

Though a reference model could be used (e.g. a desired vehicle model with a lower spring rate), in this publication is assumed  $y_{Ref,k+i} = 0$ . If the system states were known, the disturbance could be simply calculated. In this case it is not possible, so that an observer should be used, such as a *Luenberger observer* used by [7]. With the reconstructed system states the prediction model determines the output vector which subsequently has to be minimized over the prediction horizon  $n_p$ . Future disturbances are not considered so that only the knowledge of the systems dynamical behavior is used for prediction. In the course of this optimization future control variables are calculated. Thus, the vehicles dynamics is adapted towards the reference model depending on the weighting in the objective function. As the actuating energy is regarded by  $R$  in equation (4), the reference model behavior will only be achieved approximately.

The minimization of  $J_k$  can be carried out for instance with the toolbox *YALMIP* [13]. Despite the simulation duration, constraints can be simply implemented and the toolbox can be inserted into a *MATLAB/Simulink* model.

### 3.2 Solution of the optimization problem and analysis based on driving maneuvers

Within the optimization the focus is set on the diagonal, positive definite matrix  $Q \in \mathbb{R}^{rn_p \times rn_p}$  and  $R \in \mathbb{R}^{mn_p \times mn_p}$ . The entries on the diagonal denote the square weighting of output  $y_k$  and input  $u_k$  at each time step  $k, k+1, \dots, k+n_p$ . A frequency selective evaluation and sensitivity analysis leads to suitable parameters for the matrix  $Q$ . Fig. 6 gives a general overview of the strategy. A spectrum of roll acceleration can be divided for each driving maneuver in three areas which are shown in the background of the spectrum and represent the car body eigenfrequency (1-3 Hz), human sensitive frequency (4-8 Hz) and wheel eigenfrequency (11-16 Hz). The weighting of  $\varphi$ ,  $\dot{\varphi}$  or  $\ddot{\varphi}$  influences these areas differently.

Two variants of the MPC are compared with a reference axle selective control. The latter is based on a feedforward control determined directly from the relative tire deflections without considering actuator limits. Hence, if the actuator reaches its physical limit beyond the border of operating points, the desired angle or rate cannot be set. In fig. 6 the set of operating points is shown. Additionally to the constraints in equation (5), a transition band with a slope was added between torque and rotational speed limits. The torque and speed limitations were exactly satisfied if the model and the controlled system are identical. The comfort optimized MPC variant could reduce body roll acceleration hugely while the energy optimized variant shows a smaller reduction but leads to a lower energy consumption.

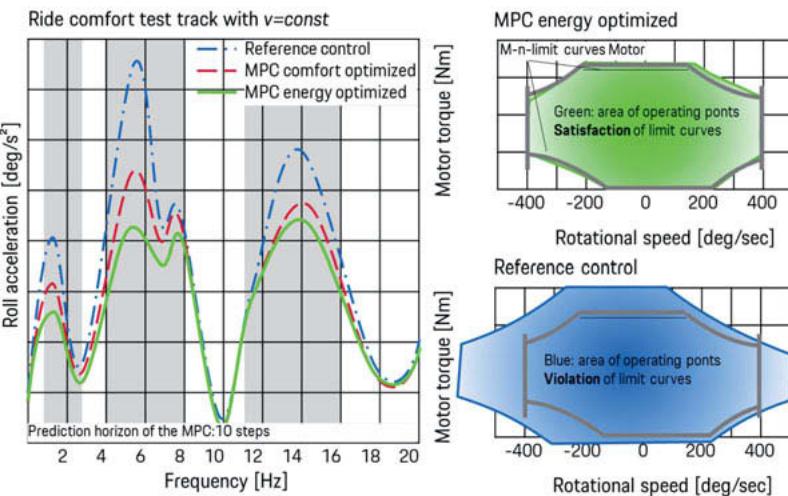


Fig. 6: Simulation result of different MPC configurations

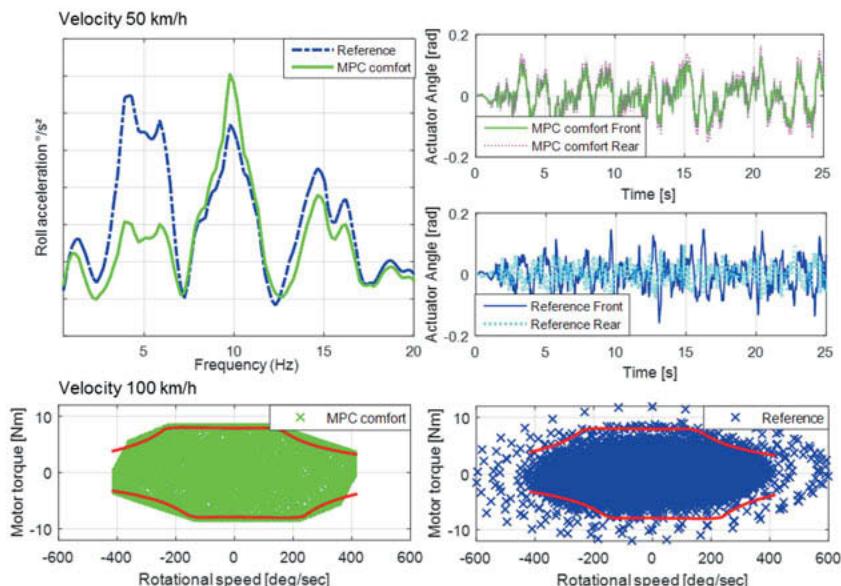


Fig. 7: Ride comfort test track simulation results with 50 km/h and 100 km/h

For further analysis many driving maneuvers have been simulated and two of them are displayed in fig. 7. With the designed weighting values for minimization of roll angle and roll rate especially the roll acceleration in the range of 4-8Hz drops when driving with 50 km/h. In the actuator angles plot one peculiarity of the MPC is shown, as the front and rear angles are almost equal. The optimization seems to determine a total vehicle related angle which is separated on both actuators only depending on the relative suspension stiffness.

As the power supply rises with higher speeds, the M-n operating points are shown for a speed of 100 km/h. Compared to a reference control, which would be not realizable due to violation of actuator limits, the designed MPC comfort variant satisfies the approximated limits in every setpoint.

All in all, a new method with only a few tunable variables has been designed and shows obviously the improvement of ride comfort in simulation. As a next step, the real-time capability should be tested.

#### 4. Realization of the MPC in a test vehicle

In many cases a model predictive control is not real-time capable and not feasible. Therefore a model reduction and faster optimization algorithms are necessary. Currently a reduced model with a faster algorithm is tested with a Rapid Prototyping System. A possible setup is shown in fig. 8.

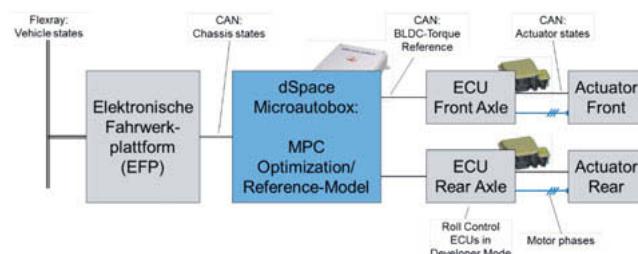


Fig. 8: Realization with a dSpace Microautobox

The implementation can be carried out between the central ECU and the separated active roll control ECUs so that most of the control signals are available. In future works the results will be presented.

## 5. Summary

Within the scope of this article the use of a model predictive control with an active roll stabilization has been analyzed. The ride comfort could be optimized even though the MPC is not commonly used for unknown disturbance compensation. The improvement is based on the considered actuator constraints and knowledge of the future vehicle behavior after an occurred disturbance. By means of the MPC an optimum between ride comfort and power consumption of a specified actuator is adjustable. Not only the power consumption decreases but also the satisfaction of constraints leads to a better controllability.

## 6. References

- [1] Koch, T.; Schlecht, A.; Smetana, T.: Elektromechanische Wankstabilisierung - Ein System zur Spreizung von Fahrdynamik und Fahrkomfort auf Basis einer 48 Volt – Energieversorgung, 25th Aachen Colloquium Automobile and Engine Technology, 2016.
- [2] Koletzko, K.: Untersuchung des Einflusses von Verstellämpfern auf das Wankverhalten von PKW unter Berücksichtigung einer aktiven Wankstabilisierung, Dissertation, München, 2008.
- [3] Adamy, J.: Nichtlineare Regelungen, Springer-Verlag, 2009.
- [4] Göhrle, C.: Model Predictive Control of semi-active and active suspension systems with available road preview, In: European Control Conference (ECC), 2013.
- [5] Cho, B.: Active suspension controller design using MPC with preview information. In: Journal of Mechanical Science and Technology, vol. 13, pp. 168 - 174, 1999.
- [6] Cho, B.; Ryu, G.; Song, S.J.: Control strategy of an active suspension for a half car model with preview information. In: International Journal of Automotive Technology, vol. 6, pp. 243–249, 2005.
- [7] Nguyen, M. Q.; Canale, M.; Sename O.; Dugard L.: A Model Predictive approach for semi active suspension control problem of a full car. In: 55th IEEE Conference on Decision and Control (CDC 2016), Las Vegas, 2016.
- [8] Canale, M.; Milanese, M; Novara, C.: Semi-active suspension control using fast model predictive control, In: Control Systems Technology, IEEE Transactions on, vol. 14, no. 6, pp. 1034 - 1046, 2006.
- [9] Giorgetti, N.; Bemporad, A; Tseng, H. E.; Hrovat, D: Hybrid model predictive control application towards optimal semi-active suspension, In: International Journal of Control, vol. 79, no. 05, pp. 521–533, 2006.

- [10] Koch, T.; Mirwaldt, T.: Regelstrategien für eine aktive Wankstabilisierung. In: Autoreg 2015, pp. 13 - 20.
- [11] Illg, I.; Freuer, A.; Eisenbarth, M.; Nareyko, G.; Koch, T.: Control Strategy for Electromechanical Active Roll Stabilization. 18. Internationales Stuttgarter Symposium Automobil- und Motorenmechanik, Stuttgart, 2018.
- [12] Li, Z.; Sun, J.: Disturbance compensating model predictive control with application to ship heading control. In: IEEE Transactions on Control Systems Technology, 20. Jg. Nr. 1, pp. 257 - 265, 2012.
- [13] Löfberg, J.: YALMIP: A toolbox for modeling and optimization in MATLAB, In: Proceedings of the CACSD Conference, Vol. 3, 2004.



## Schrittweise zum sicheren automatisierten Fahren auf der Autobahn

Dr. Dieter Hötzer, Robert Bosch GmbH, Stuttgart

Der Anteil der neu zugelassenen Pkws mit einem oder mehreren Assistenzsystemen an Bord nimmt rasant zu. Parallel dazu erhöht sich der Automatisierungsgrad stetig.

Auf dem Weg hin zum automatisierten Fahren folgen wir zwei Entwicklungspfaden. Zum einen entwickeln wir Fahrerassistenzsysteme. Sie ermöglichen schrittweise das automatisierte Fahren für im Privatbesitz befindliche Fahrzeuge in den sogenannten Automatisierungsstufen Level 2 und Level 3.

Der zweite Entwicklungspfad wird uns zu den Stufen Level 4 und Level 5, dem vollautomatisierten Fahren führen. In der US-amerikanischen Stadt San José werden wir in diesem Jahr gemeinsam mit Daimler einen automatisierten Mitfahrerservice testen. Ziel dieser Entwicklungspartnerschaft ist das fahrerlose Fahren im urbanen Umfeld.

Im Marktsegment der Privatfahrzeuge sind derzeit teilautomatisierte Assistenzsysteme verfügbar, die den Fahrer in seiner Längs- und Querführung sowohl im niedrigeren Geschwindigkeitsbereich (z.B. Stauassistent) als auch im höheren Geschwindigkeitsbereich (z.B. Autobahnassistent) unterstützen. Es ist abzusehen, dass die Unterstützungsleistung und die damit verbundene Komplexität zukünftiger Assistenzsysteme auf dem Weg zu höherer Automatisierung Schritt für Schritt zunehmen wird, z.B. durch selbstständig eingeleitete und durchgeführte Spurwechsel-, Überhol- und Einfädelmanöver. Dabei gilt in der Funktionsausprägung zu berücksichtigen, dass diese so sicher und komfortabel durchgeführt werden, dass ein Beifahrer nicht mehr erkennt, ob der Fahrer oder das Assistenzsystem das Fahrzeug steuert.

Damit verbunden steigen die Anforderungen an Sensorik, Aktoren und Steuergeräte, aber vor allem an die mittels Software codierten Algorithmen, die sukzessive die Fahraufgabe übernehmen. Dennoch bleibt der Fahrer in der Pflicht die Umgebung sorgfältig zu überwachen und ggf. einzugreifen. Um dem Fahrer eines Fahrzeugs andere Tätigkeiten (z.B. Email lesen und schreiben) und Blickabwendung vom Straßengeschehen zu ermöglichen, ist die Weiterentwicklung zum hochautomatisierten Fahren (Level 3) unumgänglich. Obwohl sich das Fahrverhalten im Vergleich zu Assistenzsystemen anfänglich nicht gravierend unterscheiden wird oder in ersten Ausprägungen sogar Einschränkungen im Einsatzbereich und in der Funktionsausprägung in Kauf genommen werden müssen, ist dieser Entwicklungsschritt enorm

hoch, schwer planbar und extrem kostenintensiv. Dies resultiert aus deutlich höheren Systemanforderungen, da der Fahrer die Fahraufgabe abgibt und das System sich selbstständig überwacht. Im Falle einer Übergabenotwendigkeit an den Fahrer müssen zudem systemische Maßnahmen ergriffen werden, um in dieser Übergangszeit ein sicheres Fahrverhalten zu gewährleisten.

Damit ein automatisiertes Fahrzeug seine Passagiere sicher ans Ziel bringt, gilt es, das System technisch so auszulegen, dass es zuverlässig und sicher arbeitet. Dazu ist eine redundante 360°-Umfelderkennung und –interpretation mit sich ergänzenden Sensortechnologien (Radar, Video, Ultraschall, Lidar) notwendig. Die dafür notwendige Performance stützt sich dabei mehr und mehr auf den Einsatz von künstlicher Intelligenz. Zusätzlich kommen eine präzise Lokalisierung sowie redundant ausgelegte Brems- und Lenksysteme hinzu.

Die Akzeptanz dieser Systeme hängt neben einer hohen Zuverlässigkeit von einem transparenten und nachvollziehbaren Nutzerinteraktionskonzept ab, wie beispielsweise der Übergabestrategie vom automatisierten System zum Fahrer und zurück.

Aufgrund des großen Entwicklungshubes für L3 Systeme und den damit verbundenen Einführungsrisiken, erfordert der Weg vom teilautomatisierten zum hochautomatisierten Fahren eine schrittweise Weiterentwicklung. So können auch zu jedem Zeitpunkt kundenwertige Funktionen zu akzeptablen Marktpreisen angeboten werden. Wir sehen eine erweiterte Funktionsroadmap mit mehreren Zwischenstufen als notwendige Vorbedingung für ein hoch verfügbares und freigabefähiges Level 3 System. Der Weg führt damit ausgehend von heutigen L2-Systemen über erweiterte L2-Ausprägungen zur Automatisierungsstufe L3.

Über diese Zwischenschritte wird auch Vertrauen geschaffen, so dass der Fahrer in der Endausbaustufe die Augen von der Straße nehmen und sich produktiveren Aufgaben widmen kann.

Das Assistenzsystem wird in diesen Zwischenschritten noch unter Aufsicht des Fahrers optimiert und lernt stetig dazu. Nach dieser Optimierungszeit, kann es selbstständig sicher und zuverlässig in allen vorgesehenen Situationen und Wetterbedingungen die Längs- und Querföhrung übernehmen. Diese Vorgehensweise ist vergleichbar mit einer Fahrschule, in der ein unerfahrener Fahrer das Fahren unter Aufsicht des Fahrlehrers erlernt und nach erfolgreicher Fahrprüfung die Verantwortung komplett übernimmt.

# A Complete Concept for Combined Longitudinal and Lateral Trajectory Planning for Automated Driving on Highways

## Ein vollständiges Konzept zur kombinierten Längs- und Quertrajektorienplanung für automatisiertes Fahren auf der Autobahn

**Jeremias Schucker M.Sc., Tobias Kohlmann M.Sc.,**

Opel Automobile GmbH, Rüsselsheim;

**Prof. Dr.-Ing. Ulrich Konigorski**, Technische Universität Darmstadt

### Abstract

A complete concept for combined longitudinal and lateral trajectory planning for automated driving on highways is presented. The concept is complemented by an approach to handle lane change abort situations which decides when a lane change abort is reasonable. The optimal trajectory is a spline consisting of up to four polynomials. Using splines to describe the trajectory allows for planning future lane changes. The cost function of the longitudinal trajectory is set up in a proper way to describe all possible highway scenarios. Thus, it is not necessary to switch between different longitudinal modes. The decision for a lane change abort is based on a simple metric that rates the criticality of unexpected changes of the traffic situation.

**Keywords** spline-based trajectory planning, lane change abort, automated driving.

### Kurzfassung

In diesem Beitrag wird ein vollständiges Konzept für die kombinierte Längs- und Querplanung für automatisierte Fahrten auf der Autobahn vorgestellt. Es wird durch einen Ansatz zur Handhabung von Fahrstreifenwechselabbrüchen ergänzt, der entscheidet, wann ein Fahrstreifenwechselabbruch sinnvoll ist. Die optimale Längs- bzw. Quertrajektorie wird durch einen Spline dargestellt, der aus bis zu vier Polynomen besteht. Durch die Verwendung von Splines können Fahrstreifenwechsel mit Startzeitpunkt in der Zukunft geplant werden. Die Gütfunktion zur Bewertung der Längstrajektorie wurde so angesetzt, dass sämtliche Autobahnmanöver abgebildet werden können. Ein Umschalten zwischen verschiedenen Modi in Längsrichtung ist hierdurch nicht notwendig. Die Entscheidung für einen Fahrstreifenwechselabbruch wird mithilfe einer einfachen Metrik getroffen, die die Kritikalität von unerwarteten Veränderungen der Verkehrssituation bewertet.

**Schwerpunkte** splinebasierte Trajektorienplanung, Fahrstreifenwechselabbruch, automatisiertes Fahren.

## 1 INTRODUCTION

To perform maneuvers such as a lane change in dense traffic scenarios, it is necessary to plan the vehicle's path in dependence of time, a trajectory. The focus of this contribution is on combined longitudinal and lateral trajectory planning, i. e. the longitudinal trajectory is not planned independently of the lateral one. Concepts for combined longitudinal and lateral trajectory planning are addressed in [2–5]. A complete concept for automated driving on highways which covers merging, lane change and lane keeping is presented in [4, 5]. The trajectories consist of one polynomial for lateral and one for longitudinal movement. To obtain the optimal trajectory the terminal manifold is discretized. For each element in the manifold a cost function is evaluated and the trajectory with the lowest cost is chosen. A downside of this approach is that it cannot plan lane changes which start in the future. Hence, a targeted approach of a gap is not possible. In [2, 3] a concept is presented where lateral and longitudinal trajectories consist of splines and, hence, enables future lane changes. The resulting optimization problem is nonlinear and, thus, it results in a much higher implementation effort compared to [4, 5]. In addition, it is not possible to guarantee that a solution can be found in real time [3].

This contribution builds up on the presented literature and combines their main advantages i. e. the simple implementation of [4, 5] and the possibility of planning lane changes starting in the future [2, 3]. Section 2 presents the basic structure of the trajectory planner while the algorithm is developed in Section 3. The trajectory planner is complemented by an approach to handle lane change abort situations in Section 4. Results are presented in Section 5 and, finally, conclusions are drawn in Section 6.

## 2 STRUCTURE OF THE TRAJECTORY PLANNER

The trajectory planner comprises two modules: the basic planner and the standstill planner, see Fig. 1. The task of the basic planner is to calculate a trajectory for an ordinary ride i. e. lane keeping, lane change or merging. The standstill planner, in contrast, always plans a trajectory into the standstill. A braking in the standstill might be necessary if a merging maneuver is not possible before the lane ends. The maximum deceleration currently available to our assistance systems is  $3 \text{ m/s}^2$  which is significantly smaller than the physical limit. Thus, the standstill trajectory is not an emergency trajectory but rather a comfortable way to transfer the vehicle into a safe state.

The standstill switch from the basic planner to the standstill planner is designed in a conservative way. Once the standstill trajectory is activated it stays active until the vehicle has fully stopped. A more sophisticated switching behavior would require a deeper understanding of the situation which is not available. The tra-

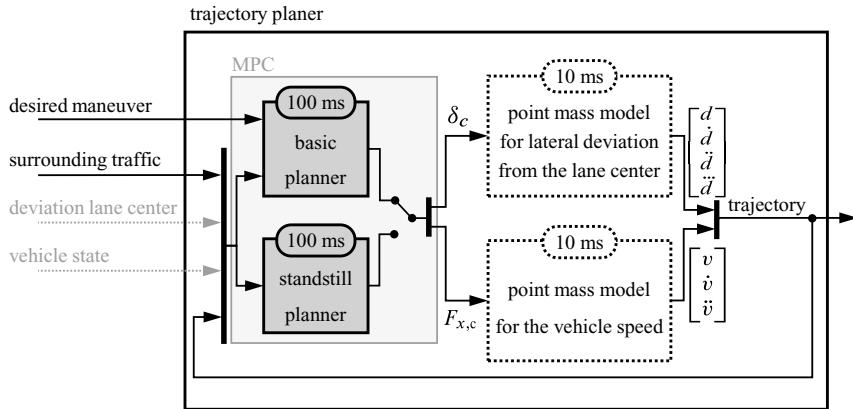


Figure 1: Structure of the trajectory planner illustrated as MPC loop

jectory planner has four input signals as illustrated in Fig 1. Those in light gray (deviation from lane center and vehicle state) are only used for the initialization of the trajectory planner. The desired maneuver is commanded by an overlaid driving strategy. The information about the surrounding traffic participants consists of the current measurements of their position, velocity and acceleration. The trajectory compromises the lateral deviation from the lane center  $d$ , the vehicle speed  $v$  and their derivatives up to a certain order. The trajectory planner itself can be considered as a model predictive control loop. It consists of the basic/standstill planner as model predictive controller (MPC) whose control signals are applied to a point mass model. The control signals are the steering wheel angle  $\delta_c$  and the driving force  $F_{x,c}$ . The trajectory thus consists of the states of the point mass models. As initial value of for each planning cycle the current state of the point mass model is fed back.

### 3 THREE-SEGMENT PLANNING

The trajectory is divided into three segments each consisting of at least one polynomial. Thus, it is possible to plan a flexible trajectory which is capable of describing a lane change starting in the future. Each segment consists of a fifth-order polynomial in longitudinal and seventh-order in lateral direction. For each segment, a swarm of longitudinal and lateral trajectories is generated by discretizing the target manifold. Out of all these trajectories the one approaching the target state in the best way according to a cost function is

chosen (see Fig. 2). The three segments have the following tasks:

- **Segment 1**

Segment 1 always describes a lane keeping trajectory. This is the primary segment to describe the future movement in case the requested maneuver does not comprise a lane change. However, if a lane change maneuver has to be performed this segment is used to approach a gap that is in far distance. To determine the length of this segment in case of a lane change it is estimated how long it takes until the gap is accessible. The segment can be omitted if the gap is already in close proximity.

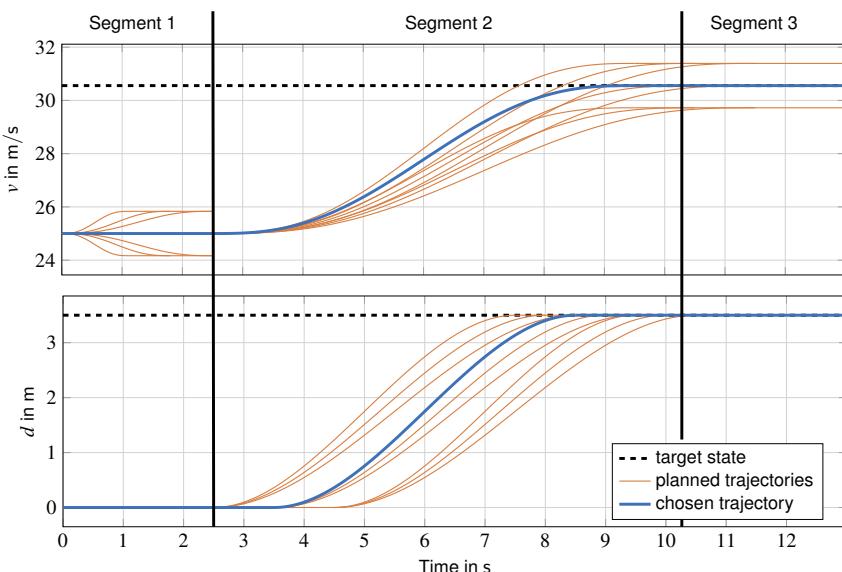


Figure 2: Illustration of the three-segment planning for a lane change with simultaneous adaption of the vehicle speed: longitudinal trajectory (top) and lateral trajectory (bottom).

- **Segment 2**

This segment is only executed if the desired maneuver contains a lane change otherwise it is omitted. The purpose of this segment is to perform the actual lane change. Therefore, the lateral trajectory in this segment is divided into two polynomials. In a first step a swarm of lane keeping polynomials is planned and afterwards in a second step for each candidate in the swarm a consecutive lane change

polynomial is generated. This can be seen in Fig. 2 by the fact, that not all trajectories start the lateral movement at the beginning of Segment 2. Thus, it is possible to purposefully approach the gap before initiating the lateral movement.

- **Segment 3**

To evaluate and compare all generated trajectories they must have the same length. Hence, all trajectories have to be extended to the same temporal length. This enables the evaluation of the trajectory also beyond the lane change. Thereby, it can be ensured that the lane change smoothly turns into a lane keeping and, thus, an anticipatory driving behavior is obtained.

### 3.1 GENERATION OF LONGITUDINAL TRAJECTORY SWARM

The longitudinal motion is planned in terms of the vehicle speed and is described by a point mass model which is extended by a second order linear actuator dynamics:

$$\begin{bmatrix} \dot{v} \\ \dot{F}_x \\ \ddot{F}_x \end{bmatrix} = \begin{bmatrix} \dot{v} \\ \dot{F}_x \\ \ddot{F}_x \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & -\omega_v^0 & -2D_v\omega_v^0 \end{bmatrix}}_{f(x_v, F_{x,c})} \begin{bmatrix} v \\ F_x \\ \dot{F}_x \end{bmatrix} + \underbrace{\begin{bmatrix} 0 \\ 0 \\ K_v\omega_v^1 \end{bmatrix}}_{F_{x,c}} \quad \left. \begin{array}{l} \text{point mass model} \\ \text{actuator dynamics} \end{array} \right\} . \quad (1)$$

$F_{x,c}$  is the control input while the actuator dynamics is described by its states  $F_x$  and  $\dot{F}_x$  with the corresponding parameters  $D_v$ ,  $K_v$  and  $\omega_v$ . For simplicity, the actuator dynamics is simplified so that the full model becomes a single integrator chain of order three. The states of the actuator dynamics can also be considered as higher derivatives of the vehicle speed. The task of longitudinal trajectory planning is to set a desired velocity. This task can be described by the following optimization problem:

$$\min_{F_{x,c}(\cdot)} J_v(F_{x,c}) = \underbrace{k_{t_{e,v}} t_{e,v} + k_v (v(t_{e,v}) - v_{\text{des}}(t_{e,v}))^2}_{\text{terminal costs}} + \underbrace{\frac{1}{2} \int_{t_0}^{t_{e,v}} F_{x,c}^2(t) dt}_{\text{integral cost}} \quad (2a)$$

$$\text{subject to} \quad \dot{x}_v = \mathbf{f}(x_v, F_{x,c}), \quad x_v(t_0) = x_{v,0} \quad (2b)$$

$$v(t) \leq v_{\text{max}} \quad (2c)$$

$$x_{v,i}(t_{\text{e}}) = x_{v,e,i}, \quad i \in \{1, 2, 3\}. \quad (2d)$$

The cost function  $J_v$  is separated into integral and terminal cost with their weighting factors  $k_{l_{c,v}}$  and  $k_v$ . The terminal costs penalize the state at the final time  $t_{c,v}$ . It consists of two parts. The first term penalizes the temporal length of the trajectory and the second ensures that the desired velocity  $v_{des}$  is set. For a comfortable driving style the control effort should be low. This is ensured by the integral cost which penalizes the control actions. To avoid huge velocities in the case where the leading vehicle is far away or nonexistent it is necessary to limit the vehicle speed to a maximum velocity  $v_{max}$ . The maximum velocity is the minimum of the desired speed of the driver and the road speed limit. The optimal solution is a fifth order polynomial [4]. To obtain the swarm of trajectories the terminal manifold, which consists of the final time and final velocity, is discretized. Thus, the trajectory can only arrive at a discrete number of final times and velocities. The trajectory swarm is finally obtained by generating a trajectory for each pair of values of the discretized manifold.

The cost function used to generate the longitudinal trajectory swarm does not consider the distance to the leading vehicle. To ensure that the trajectory with the best following behavior is selected the trajectory swarm is evaluated by the following extended cost function:

$$J_{v,l}(F_{x,c}) = J_v(F_{x,c}) + k_l(l(t_{c,v}) - l_{des}(t_{c,v}))^2. \quad (3)$$

$k_l$  is the weighting factor for the deviation of the actual  $l$  from the desired distance to the leading vehicle  $l_{des}$  at the end of the maneuver. The required distance at the end of the maneuver can be obtained from the corresponding velocity trajectory by integration.

### 3.2 GENERATION OF LATERAL TRAJECTORY SWARM

The lateral motion is planned in terms of the deviation from the lane center. It is described by a point mass model which is extended by a simplified actuator dynamics:

$$\begin{bmatrix} \dot{d} \\ \ddot{d} \\ \dot{\delta} \\ \ddot{\delta} \end{bmatrix} = \underbrace{\begin{bmatrix} \dot{d} \\ \ddot{d} \\ \dot{\delta} \\ \ddot{\delta} \end{bmatrix}}_{\dot{x}_d} = \underbrace{\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \end{bmatrix}}_{f(x_d, \delta_c)} \begin{bmatrix} \dot{d} \\ \ddot{d} \\ \dot{\delta} \\ \ddot{\delta} \end{bmatrix} + \underbrace{\begin{bmatrix} 0 \\ 0 \\ 0 \\ K_d \omega_d^2 \end{bmatrix}}_{\delta_c} \quad . \quad (4)$$

$\omega_d^2$   $-2D_d \omega_d$   $K_d \omega_d^2$

The actuator dynamics is described by its states  $\delta$  and  $\dot{\delta}$  and its parameters  $D_d$ ,  $K_d$  and  $\omega_d$ .  $\delta_c$  is the control input. The goal of lateral trajectory planning is to guide the vehicle along the current lane center

or, in case of a lane change, to the destination lane center. Formulated as optimization problem one obtains:

$$\min_{\delta_c(\cdot)} J_d(\delta_c) = \underbrace{k_{t_{e,d}} t_{e,d}}_{\text{terminal cost}} + \underbrace{\frac{1}{2} \int_{t_0}^{t_{e,d}} \delta_c^2(t) dt}_{\text{integral cost}} \quad (5a)$$

$$\text{subject to} \quad \dot{x}_d = f(x_d, \delta_c), \quad x_d(t_0) = x_{d,0} \quad (5b)$$

$$x_{d,j}(t_e) = x_{d,e,j}, \quad j \in \{1, 2, 3, 4\}. \quad (5c)$$

The cost function  $J_d$  has only one weighting factor  $k_{t_{e,d}}$  and, thus, it is very simple to tune. Choosing a large weighting factor results in a fast lane change and a short temporal length of the trajectory  $t_{e,d}$ . If the comfort of the trajectory shall be emphasized the weighting factor should be chosen low. The solution to this optimization problem are polynomials of seventh order [4]. The trajectory swarm is obtained by analogy to the longitudinal trajectory generation.

### 3.3 SELECTION OF THE BEST TRAJECTORY

The described generations of longitudinal and lateral trajectories are used to plan each segment. Apart from the velocity restriction the trajectories describe the solution to an unrestricted optimization problem. Thus, they may cause collisions or violate physical limits of the actuators. To check if the trajectory is collision free a sample-based method is used. For each sample point it is verified that all the surrounding vehicles, which are on the same lane, do not fall below a minimum distance. If this condition is violated at any point the associated trajectory is discarded. The compliance of the physical limits and the speed limitation is verified in the same manner. Out of all the valid trajectories the one with lowest total cost is chosen:

$$J_{\text{tot}} = J_{v,l, \text{Segment 1}} + J_{v,l, \text{Segment 2}} + J_{v,l, \text{Segment 3}} + J_{d, \text{Segment 1}} + J_{d, \text{Segment 2}} + J_{d, \text{Segment 3}} \quad (6)$$

where  $J_{v,l,(\cdot)}$  and  $J_{d,(\cdot)}$  are the lateral and longitudinal costs for each segment, respectively.

### 3.4 APPLICATION TO HIGHWAY DRIVING

In this section the proposed planning concept is applied to perform highway maneuvers i. e. lane keeping, lane change, enter and exit the highway. The lane keeping maneuver is straightforward and does not need

any further explanation. The remaining three maneuvers are shortly introduced. The vehicle performing the planning algorithm is called ego vehicle (see Fig. 3).

### LANE CHANGE

The desired temporal distance in terms of time gap to a leading vehicle on German highways is  $T_{\text{des}} = 1.8\text{s}$ . Although, in common traffic situations the available gaps are too small to maintain the full desired temporal distance. To perform a lane change in such gaps a proper smaller temporal distance  $T_{\text{red}}$  has to be chosen. A possible choice would be the minimum temporal distance  $T_{\text{min}} = 0.9\text{s}$  which is exempt from punishment [1]. Nevertheless, it is not desirable to use the minimum allowed time gap unless it is necessary. Thus, a gap size dependent temporal distance is chosen:

$$T_{\text{red}}(t) = \min(T_{\text{des}}, T_{\text{min}} + k_T T_{\text{free}}(t)), \quad k_T \in [0, 1] \quad (7a)$$

$$\text{with} \quad T_{\text{free}}(t) = \frac{l_{\text{free}}(t)}{v(t)}. \quad (7b)$$

$l_{\text{free}}$  is the accessible length of the gap as shown in Fig. 3. The parameter  $k_T$  is used to choose the position within the accessible area of the gap. For  $k_T = 1$  the minimal distance to the tailing vehicle of the gap is chosen and for  $k_T = 0$  the minimal distance to the leading vehicle. To avoid a huge temporal distance for large gaps the maximum value is limited to  $T_{\text{des}}$ . To imitate human driving behavior, parameter  $k_T$  should be chosen  $k_T < 0.5$  for a lane change to left and  $k_T > 0.5$  for a lane change to the right.

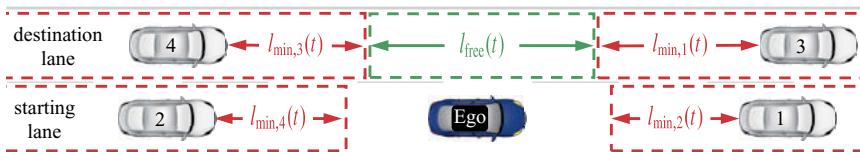


Figure 3: Illustration of the accessible length of the gap  $l_{\text{free}}$  (green) and minimal safety distances  $l_{\text{min},(\cdot)}$  (red) for a left lane change of the ego vehicle.

### ENTER AND EXIT HIGHWAY

A highway enter maneuver can be considered as a lane change that has to be completed within a limited road stretch. An adjustment of the trajectory planner to handle this situation shall be avoided. To do so a

virtual vehicle with a speed of 0 m/s is placed at the end of the ramp (see Fig. 4). If no valid trajectory to enter the highway can be found the standstill planner ensures a safe stop at the end of the ramp. A highway exit maneuver can be performed in the same manner with the only difference that the virtual vehicle is placed at the beginning of the exit ramp. This way it can be ensured that the exit maneuver is not started before the ramp begins.

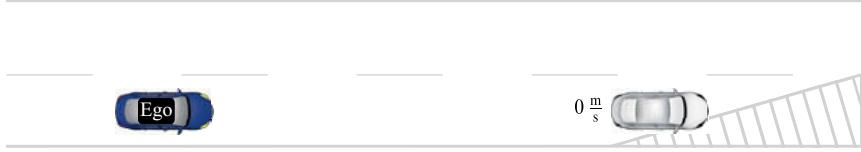


Figure 4: Virtual vehicle (gray) at the highway ramp to fake lane end.

#### 4 APPROACH TO HANDLE LANE CHANGE ABORTS

A successful completion of a lane change maneuver primarily depends on an accurate perception and future prediction of the environment. However, measurements are usually defective and the prediction models are basically not more than a good guess about the future. Hence, situations where all lane change trajectories become invalid due to violation of safety distances become inescapable. A decision must be taken whether to continue or abort the lane change maneuver in such a situation. This can be done by an evaluation and comparison of the criticality of a possible abort maneuver with a continuation of the lane change. For the evaluation only the most critical point to each surrounding vehicle is considered. This point is defined by the maximum critical cost  $J_{\text{crit}}$  to the respective surrounding vehicle:

$$J_{\text{crit},h} = \max_{t \in [0, t_c]} J_h(t), \quad h \in \{1, 2, 3, 4\} \quad (8a)$$

$$\text{with} \quad J_h(t) = \begin{cases} 0, & I_h(t) \geq w_{\text{red}}(t)l_{\min,h}(t) \\ \left( \frac{I_h(t) - w_{\text{red}}l_{\min,h}(t)}{w_{\text{red}}l_{\min,h}(t)} \right)^2, & \text{else} \end{cases} \quad (8b)$$

The cost  $J_h(t)$  describes the squared percentage shortfall of the current distance  $I_h(t)$  to a reduced minimal safety distance. The reduction factor  $w_{\text{red}}$  weights the relative speed at the critical point. If the relative speed is negative the situation is less severe and thus a smaller safety distance is acceptable. The sigmoid-

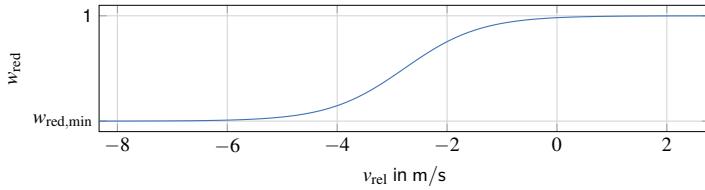


Figure 5: Exemplary course of the sigmoid-shaped reduction factor in dependence of the relative velocity.

shaped reduction factor is illustrated in Fig. 5 and is limited to a minimum reduction value of  $w_{\text{red,min}}$ . To obtain the total critical cost of the continuation of the lane change  $J_{\text{crit,LC}}$  and the abort maneuver  $J_{\text{crit,A}}$ , respectively, the cost of the surrounding vehicles is summed up:

$$J_{\text{crit},(\cdot)} = J_{\text{crit},1} + J_{\text{crit},2} + J_{\text{crit},3} + J_{\text{crit},4}. \quad (9)$$

The lane change is aborted if the total critical cost for the lane change is greater than an augmented total cost of the abort maneuver

$$J_{\text{crit,LC}} > k_A J_{\text{crit,A}}. \quad (10)$$

Through the augmentation of cost for the abort maneuver by the weight  $k_A$  the continuation of the lane change is slightly privileged. This leads to a more natural driving behavior and supports the fulfillment of the requested lane change.

## 5 RESULTS

The proposed concept was implemented in simulation as well as in a prototype vehicle. The maximum measured computing time to plan a lane change was less than 30 ms on a dSPACE DS1007 processor board. Thus, within a cycle time of 100 ms lane changes for at least three different gaps can be planned. An exemplary trajectory for a lane change abort maneuver is illustrated in Fig. 6. A valid lane change trajectory can be found quite early. Hence, in Segment 1 (S1) the ego vehicle first needs to wait for the gap to come closer before it starts the targeted approach of the gap with the beginning of Segment 2 (S2). After roughly seven seconds the leading vehicle on the destination lane starts a harsh braking maneuver. As a result, the lane change has to be aborted and the ego vehicle is guided back safely to the starting lane in Segment 3 (S3).

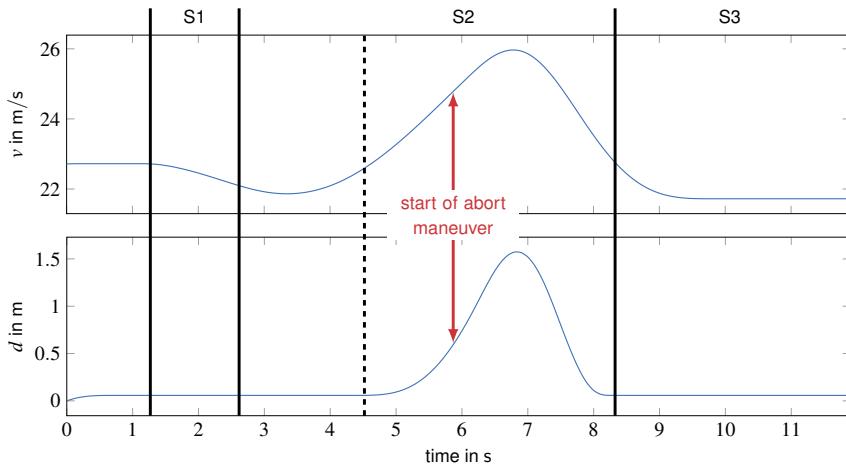


Figure 6: Exemplary course of an aborted lane change maneuver to the left. Segment 2 consists of two polynomials which is separated by the dashed line.

Figure 7 shows the shortfall of the reduced minimal safety distance for the leading vehicle on the destination lane  $\Delta l_3(t) = l_3(t) - w_{\text{red}} l_{\min,3}(t)$  for the abort maneuver and a possible continuation of the lane change. If the ego vehicle does not occupy the destination lane the shortfall is zero. In case of the abort maneuver it is always greater zero during the occupation of the destination lane. Hence, the maneuver is safe. In contrast for a possible continuation of the lane change the ego vehicle would significantly fall below the reduced minimal safety distance.

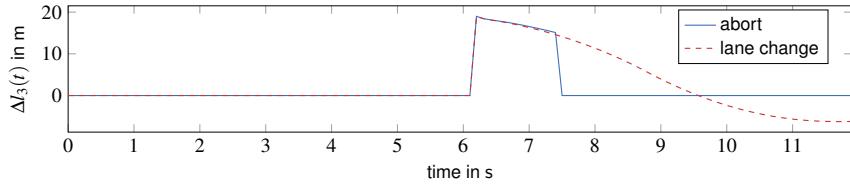


Figure 7: Illustration of the shortfall to the leading vehicle on the destination lane for an unforeseen change of the traffic situation during a lane change maneuver.

## 6 CONCLUSIONS AND FUTURE WORK

A complete trajectory planning concept for automated driving on highways has been presented. It compromises three segments such that it is possible to plan lane changes in the future. By choosing a subtle cost function the number of longitudinal modes can be reduced to one. In addition, the concept can handle lane change abort scenarios. The trajectory planner has been tested so far only on a test ground and in simulation. A next step would be to validate if satisfying results can also be obtained on public roads.

## REFERENCES

- [1] Bundesministerium der Justiz und für Verbraucherschutz. Verordnung über die Erteilung einer Verwarnung, Regelsätze für Geldbußen und die Anordnung eines Fahrverbotes wegen Ordnungswidrigkeiten im Straßenverkehr (Bußgeldkatalog-Verordnung): Bkav, 2013-03-14.
- [2] Christian Götte, Christian Wissing, Martin Keller, Till Nattermann, Carsten Haß, Karl-Heinz Glander, and Torsten Bertram. Simulationsbasierte Entwicklung eines Trajektorienplanungsverfahrens für automatisiertes Fahren. In *AUTOREG*, VDI-Berichte, pages 247–258. VDI Verlag GmbH, 2017. ISBN 9783180922928.
- [3] Tim Hansen, Michael Schulz, Michael Knoop, and Ulrich Konigorski. Trajektorienplanung für automatisierte Fahrstreifenwechsel. *ATZ – Automobiltechnische Zeitschrift*, 118(7–8):66–71, 2016.
- [4] Christian Rathgeber, Franz Winkler, and Steffen Müller. Kollisionsfreie Längs- und Quertrajektorienplanung unter Berücksichtigung fahrzeugspezifischer Potenziale. *at – Automatisierungstechnik*, 64(1):61–76, 2016.
- [5] Moritz Werling, Sören Kammel, Julius Ziegler, and Lutz Gröll. Optimal trajectories for time-critical street scenarios using discretized terminal manifolds. *The International Journal of Robotics Research*, 31(3):346–359, 2012.

# Decentralized Path Planning for Cooperating Autonomous Vehicles

**Simon Rothfuß, Rinat Prezdnyakov,**  
**Dr.-Ing. Michael Flad, Prof. Dr.-Ing. Sören Hohmann,**  
Institute of Control Systems (IRS) at the  
Karlsruhe Institute of Technology (KIT), Karlsruhe

## Zusammenfassung

Ein wesentlicher Bestandteil eines autonom fahrenden Fahrzeugs ist die automatisierte Pfadplanung. Die entstehenden Pfade müssen jedoch eine Kollisionsfreiheit garantieren, die in bestimmten Situationen, beispielsweise auf Parkplätzen, eine herausfordernde Aufgabe darstellt. In dieser Arbeit stellen wir einen dezentralen Pfadplanungs- und Verhandlungsalgorithmus für solche Szenarien vor. Die Pfadplanung basiert auf einer innovativen A\*-Erweiterung, die auch dynamische Hindernisse sowie Geschwindigkeitsänderungen berücksichtigt. Außerdem umfasst das Framework einen dezentralen Pfadverhandlungsalgorithmus um sich kooperativ auf kollisionsfreie Pfade für alle relevanten Fahrzeuge zu einigen. Der resultierende, iterative Prozess findet eine deterministische Lösung mit einer bekannten endlichen Anzahl von Iterationen und ist außerdem robust gegenüber begrenztem System- und Kommunikationsversagen. Abschließend zeigen Simulationsergebnisse anhand von zwei Testszenarien die Fähigkeit des Konzepts zur erfolgreichen Einigung auf kollisionsfreie Pfade.

## Abstract

A crucial part in autonomous driving is the automated path planning. The resulting paths need to collision-free which is challenge in certain free-space scenarios, e.g. a parking lot situation. In this work we propose a decentralized path planning and negotiation algorithm for such scenarios. The path planning is based on an innovative A\* extension that incorporates dynamic obstacles and the abilities of participating vehicles to change their speed. Furthermore the framework includes a decentralized path negotiation approach to cooperatively agree on collision-free paths for all relevant vehicles. The resulting iterative process of calculating new paths and negotiating a feasible solution set for all vehicles is designed to yield a deterministic solution within a known finite number of iterations. The concept is also robust towards limited system or communication failure. Last we provide simulation results of two test scenarios that show the capabilities of the framework to reach an agreement in conflict-free paths.

## Einführung

Mit der zunehmenden Automatisierung von Aufgaben und Abläufen in der Produktions- und Automobilindustrie benötigen autonome mobile Plattformen wie mobile Roboter oder autonome Autos die Fähigkeit, konfliktfreie Pfade zu planen und diese mit anderen autonomen Agenten zu verhandeln. Straßennetze mit definierten Interaktionsregeln oder definierte Bewegungskorridore erleichtern diese Planung und Verhandlung. In Freiraumszenarien, z.B. einer interaktiven Produktionsanlage, ist das Auffinden von konfliktfreien Pfaden jedoch eine noch schwierigere Aufgabe, die für vollständig autonome mobile Plattformen von großer Bedeutung ist. Dies liegt daran, dass in Freiraumszenarien viele mobile Einheiten eine gemeinsame Betriebsfläche vorfinden und es zunächst keine vordefinierten Regeln wie im Sinne z.B. einer Straßenverkehrsordnung gibt. In diesen Situationen führt einerseits die egoistische Pfadplanung vieler Fahrzeuge einerseits sehr wahrscheinlich zu Konflikten, die zur gegenseitigen Blockade oder sogar zu Kollisionen führen können. Andererseits führt ein vollständig passives Verhalten autonomer Fahrzeuge jedoch wahrscheinlich zu Stillstand oder zumindest zu einer eingeschränkten Gesamtleistung. Eine gebräuchliche Lösung für die automatisierte Pfadplanung in solchen Situationen erfordert, dass eine zentrale Recheneinheit oder ein Koordinator konfliktfreie Pfade findet, vgl. [3,6,7] oder eine statische Priorisierung der teilnehmenden Fahrzeuge [1,4].

In dieser Arbeit schlagen wir jedoch ein kooperatives, dezentrales Framework bestehend aus einem Pfadplanungs- und einem Pfadverhandlungsverfahren für Freiraumszenarien vor. Wir konzentrieren uns auf die Aushandlung konfliktfreier Pfade zwischen autonomen Fahrzeugen und führen daher die Pfadplanung auf einer abstrakten Navigationsebene, vgl. [2], durch. Die Pfadplanung wird mit einem innovativen Graphen-Suchalgorithmus auf Basis des A\*-Algorithmus realisiert. Er ist in der Lage, dynamische Hindernisse wie manuell betriebene Fahrzeuge und andere autonome Fahrzeuge sowie Geschwindigkeitsveränderungen der Fahrzeuge zu berücksichtigen. Auf Basis der Graphen-basierten Pfadplanung wird ein iteratives dezentrales Verhandlungsverfahren zur kooperativen Bestimmung eines konfliktfreien Satzes von Pfaden vorgestellt: Jedes autonome Fahrzeug plant iterativ seinen eigenen Pfad in einem vorab definierten Graphen der Umgebungskarte und teilt ihn den anderen autonomen Fahrzeugen mit, um eine realisierbare, kollisionsfreie Menge von Pfaden für alle Fahrzeuge auszuhandeln. Die Vorteile dieses Ansatzes sind vielfältig: Der Arbeitsaufwand für die Pfadplanung wird auf alle Fahrzeuge verteilt. Außerdem ist keine zentrale Recheneinheit erforderlich, da die Menge kollisionsfreier Pfade kooperativ gefunden wird. Darüber hinaus sorgt der Algorithmus dafür, Lösungen durch Priorisierung anhand der Planungsflexibilität deterministisch und mit einer begrenzten Anzahl von Iterationen zu finden. Die Dezentralisierung setzt lediglich voraus, dass

autonome Fahrzeuge miteinander kommunizieren können und die Regeln des Planungsverfahrens befolgen.

Zur Bewertung unseres Ansatzes betrachten wir ein System von autonomen Fahrzeugen, die miteinander kommunizieren können und am kooperativen dezentralen Pfadplanungsprozess teilnehmen. Ziel ist es, Pfade für alle Fahrzeuge von ihren Startpunkten zu ihren Zielpunkten so zu finden, dass zu keinem Zeitpunkt Kollisionen zwischen den Fahrzeugen oder Hindernissen auftreten. Das vorgestellte Verfahren konzentriert sich auf die Aufgabe der kooperativen Pfadplanung und -verhandlung. Es wird vorausgesetzt, dass andere Funktionseinheiten, die für die Kommunikation, Hinderniserkennung und Bewegungsschätzung usw. erforderlich sind, als gegeben angenommen werden können.

Diese Arbeit ist wie folgt aufgebaut: Der Abschnitt *Modellierung des Anwendungsszenarios* stellt das Szenario für die Implementierung des Verfahrens vor, welche in Abschnitt *Pfadplanung und Verhandlungsverfahren* vorgestellt wird. Auf die *Simulationsergebnisse* folgen die abschließenden Bemerkungen in der *Zusammenfassung*.

### **Modellierung des Anwendungsszenarios**

Da unser Ziel eine kooperative Pfadplanung auf Navigationsebene in Freiraumszenarien mit Fokus auf Verhandlungsprozesse mit vielen autonomen Fahrzeugen ist, benötigen wir nur eine approximierte Pfadplanung, die für den abstrakten Verhandlungsprozess ausreichend genau ist. Zweifellos ist während der Pfadausführung eine detailliertere und reaktionsschnellere Pfadplanung erforderlich, die nicht Gegenstand dieser Arbeit ist.

Darüber hinaus treffen wir weitere Annahmen, um uns auf die abstrakte Pfadplanung und Verhandlung konzentrieren zu können. Eine dieser Annahmen ist, dass die autonomen Fahrzeuge miteinander kommunizieren können. Eine andere ist die Annahme einer öffentlichen Umgebungskarte, die durch einen Graphen  $\mathcal{G}(\mathcal{N}, \mathcal{E}, \mathcal{W})$  dargestellt werden kann. Die Knoten  $\mathcal{N}$  repräsentieren äquidistante und gleichmäßig verteilte physische Bereiche, die den Raum ausfüllen, der für die Fahrzeuggeometrie in Bezug auf verschiedene Geschwindigkeitsstufen und Sicherheitsmargen erforderlich ist. Um die Gesamtfahrzeit und den Energieverbrauch zu minimieren, verfolgen wir das Paradigma, dass wir, anstatt anzuhalten, lieber in Bewegung bleiben und mögliche Umwege in Kauf nehmen, falls eine einfache Verzögerung durch Verringerung der Geschwindigkeit nicht ausreicht. Außerdem gehen wir davon aus, dass momentane Geschwindigkeitsänderungen, die begrenzt und nur beim Übergang von einem Knoten zu einem anderen Knoten möglich sind, eine gute Annäherung an die Längsbewegung von Fahrzeugen auf Navigationsebene sind. Auf solche Weise sind die Geschwindigkeitsstufen  $v$  wie

folgt definiert: Jede mobile Einheit kann einen Knoten innerhalb von einem, zwei, usw. Zeitschritten zurücklegen.

Es wird angenommen, dass die Kanten  $\mathcal{E}$ , die die Knoten  $\mathcal{N}$  verbinden, den holonomischen kinematischen Beschränkungen aller beteiligten Fahrzeuge entsprechen. Zu diesem Zweck muss bei der Kantendefinition die Vorgängerkante  $e_p$  berücksichtigt werden, durch die ein Knoten  $n_1$  angefahren wurde:

$$e: (e_p, n_1) \rightarrow n_2, \quad e, e_p \in \mathcal{E}, \quad n_1, n_2 \in \mathcal{N}$$

Die Gewichtung  $w(e) \in \mathcal{W}$ , die einer Kante  $e \in \mathcal{E}$  zugeordnet wird, kann Kosten wie Entfernung, Energieverbrauch, Zeitverzögerung usw. repräsentieren.

Daher muss der Graphenaufbau in Szenarien mit anderen kinematischen Einschränkungen so angepasst werden, dass eine geeignete Pfadplanung für kooperative Pfadverhandlungen möglich ist.

Ein weiterer Modellierungsaspekt ist eine Kollision, welche auftritt, wenn zwei Fahrzeuge oder ein Fahrzeug und ein Hindernis sich in demselben Knoten befinden. Daher muss das autonome Fahrzeug bei der Planung andere Fahrzeuge als bewegliche Hindernisse berücksichtigen. Deswegen wird das Konzept dynamischer Hindernisse eingeführt. Ein dynamisches Hindernis belegt nur zeitlich einen Knoten, d. h. die Position des dynamischen Hindernisses variiert zeitabhängig. Damit werden die Bewegungspläne aller anderen Fahrzeuge in Form von Sequenzen aus Knoten-Zeit-Tupeln  $(n, t) \in \mathcal{N} \times \mathbb{R}$  als dynamische Hindernisse während der Pfadplanung und -verhandlung betrachtet. Darüber hinaus wird davon ausgegangen, dass statische und dynamische Hindernisse, die durch statisches Kartenmaterial und vorhandene Bewegungsvorhersagealgorithmen bekannt sind, für alle autonomen Fahrzeuge vor der Routenplanung in Form der Umgebungskarte verfügbar sind.

Schließlich wird davon ausgegangen, dass alle autonomen Fahrzeuge denselben Pfadplanungsalgorithmus verwenden und demselben Verhandlungsprotokoll folgen, die beide im folgenden Abschnitt erläutert werden. Dies hat den Nachteil, dass in einer praktischen Implementierung im Automobilsektor gesetzliche Regelungen zur Begrenzung des Missbrauchs durch Manipulation der Priorisierung erforderlich sind und eine regelmäßige und konsistente Aktualisierung der Einstellungen der Umgebungskarte und der Algorithmen erforderlich ist. Für mobile Roboter in der Logistik und Industrie 4.0 treten diese Probleme jedoch nicht auf, da ein gemeinsamer Anlagenbetreiber und damit ein gemeinsames Ziel der Interaktion besteht.

Für die aktuelle Implementierung ist die Umgebungskarte im Rahmen dieser Arbeit als Wabenstruktur aufgebaut, siehe Abbildung 4 in Abschnitt *Simulationsergebnisse*. Dies ermöglicht eine intuitive grafische Darstellung des Graphen, d.h. der Umgebungskarte. Statische Hinder-

nisse sind unzugängliche Knoten und werden im Folgenden durch schwarze Waben symbolisiert (vgl. Bild 4). Der Vorteil des Wabenmodells besteht außerdem darin, dass eine Form der approximierten mobilen Roboterkinematik direkt enthalten ist: Für die Beschreibung der Kinematik wird ein Modell mit sechs Bewegungsmanövern verwendet. Abhängig von der Richtung, in der der mobile Roboter eine Wabe betreten hat, kann er entweder geradeaus fahren oder rechts oder links um  $\pm 45^\circ$  abbiegen.

Im nächsten Abschnitt wird der eigentliche Pfadplanungs- und Verhandlungsalgorithmus für diese Szenarien vorgestellt.

### Pfadplanung und Verhandlungsverfahren

In diesem Abschnitt wird zunächst der graphenbasierte Pfadplanungsalgorithmus vorgestellt, der die Grundlage für den anschließend vorgestellten kooperativen Verhandlungsalgorithmus für konfliktfreie Pfade bildet. Das Framework aus beiden Algorithmen eignet sich für Szenarien, die im Abschnitt *Modellierung des Anwendungsszenarios* beschrieben werden.

#### EA\*-Algorithmus

Die graphenbasierte Pfadplanung erfolgt mit einem Extended A\* (EA\*) - Algorithmus. Der Suchgraph basiert auf den Annahmen und Definitionen des Abschnitts *Modellierung des Anwendungsszenarios*. Die Hauptunterschiede zu einem herkömmlichen A\* -Algorithmus wie in [5] sind folgende:

1. Integration dynamischer Hindernisse,
2. Verschiedene Fahrzeuggeschwindigkeitsstufen
3. Ermöglicht das Beschleunigen und Abbremsen von Fahrzeugen.

Alle diese Unterschiede erfordern die Betrachtung von Zeitschritten innerhalb des Algorithmus und ändern daher den Fokus des klassischen A\* von dem Bewertungskriterium Abstand zwischen Knoten zu Zeit innerhalb eines Knotens. Das heißt, ein Fahrzeug kann sich mehrere Zeitschritte in einem Knoten aufhalten bevor es sich in einen Nachbarknoten begibt. Als Ergebnis werden in der Offenen Liste - Open List (OL) Tupel  $(X_i, k, v, X_i^P)$  der Knoten  $X_i$ , die vom Algorithmus entdeckt wurden, den Zeitschritt  $k$ , in dem der Knoten besucht wurde, die wählbare Geschwindigkeit  $v$ , mit der dieser Knoten überquert wird und der Vorgängerknoten  $X_i^P$  von  $X_i$  gespeichert. Die Geschlossene Liste – Closed List (CL) beinhaltet alle Tupel der OL, die vom Algorithmus vollständig bzgl. ihrer Nachfolertupel bearbeitet wurden. Außerdem hat jedes Fahrzeug eine individuelle Höchstgeschwindigkeitsstufe  $v_{max}$ .

Das Ablaufdiagramm des gesamten Algorithmus ist in Abbildung 2 dargestellt.

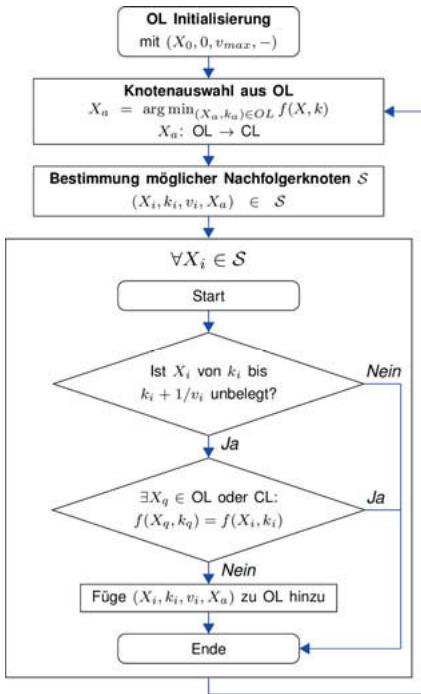


Bild 2: Ablaufdiagramm des EA\*-Algorithmus

Infolgedessen ergeben sich hauptsächlich folgende Verfahrensunterschiede zum herkömmlichen A\* -Algorithmus:

1. Suche nach neuen Knotentupel: Nicht nur die Kanten, sondern auch die unterschiedlichen Geschwindigkeitsstufen beeinflussen die Suche nach neuen Knotentupeln.
2. Prüfung der Knotenverfügbarkeit: Zusätzlich zur statischen Belegung der Knoten muss geprüft werden, ob ein Knoten für die entsprechende Zeitspanne frei ist oder durch ein dynamisches Hindernis blockiert ist.
3. Akzeptanz von Knotentupeln für die OL: Die Bedingung für das Hinzufügen eines Knotentupels zur OL werden gelockert.
4. Knotenauswahl aus OL: Die Auswahl erfolgt anhand der Kostenfunktion  $f(\cdot)$ . Diese ist eine Kombination aus den Kosten  $g(\cdot)$  vom Startknoten  $X_0$  bis zum Knoten  $X_a$  und dem heuristischen Anteil  $h(\cdot)$ , mit dem die Kosten von  $X_a$  bis zum Zielknoten  $X_g$  abgeschätzt werden:  $f(X_a, k_a) = g(X_0, X_a, k_a) + h(X_g, X_a, k_a)$ . Unter Kosten ist hier meist die Reisezeit zwischen den Knoten(-tupeln) zu verstehen. Der Knoten mit den minimalen Kosten wird

zu Beginn jeder Iteration ausgewählt und in das entsprechende Tupel in die CL verschoben.

Der so vorgestellte EA\* bildet die Grundlage des Pfadplanungs-Frameworks. Wenn kein stochastisches Element in z.B. den Kostenfunktionen enthalten ist, so liefert EA\* eine deterministische Pfadberechnung. Darauf aufbauend wird im nächsten Abschnitt der kooperative Verhandlungsprozess für eine Einigung auf konfliktfreie Pfade vorgestellt.

### ***Kooperative Verhandlung konfliktfreier Pfade: das Iterative Priorisierungsverfahren***

Im Folgenden wird der Ablauf des Iterativen Priorisierungsverfahrens (IPV) erläutert. IPV ist ein kooperativer Verhandlungsalgorithmus, der nach einer Menge konfliktfreier Pfade für mehrere Fahrzeuge sucht, indem er die Konzepte prioritätsbasierter Planungsalgorithmen [1,4] und des Multi-Party-Collision-Avoidance-Algorithmus (MPCA) [6] kombiniert und integriert. Infolgedessen profitieren wir von einer bekannten, begrenzten Anzahl von Algorithmus-Iterationen und einer verteilten Arbeitslast durch Dezentralisierung.

Zur Vereinfachung wird im Folgenden eine Menge von Pfaden, die genau einen Pfad jedes Fahrzeugs umfasst, als Pfadkombination bezeichnet. Daher zielt das IPV darauf ab, eine konfliktfreie Pfadkombination zu finden. Jede Iteration des IPV umfasst acht Schritte, wie in Abbildung 3 dargestellt. Diese Iterationen werden von allen teilnehmenden Fahrzeugen gleichzeitig durchgeführt. Zu Beginn des IPVs nehmen alle N autonomen Fahrzeuge teil.

Jede Iteration beginnt mit einer individuellen Pfadplanung unter Berücksichtigung aller statischen und dynamischen Hindernisse, insbesondere der bekannten Pfade anderer autonomer Agenten. Anschließend werden einige Merkmale des gefundenen Pfads, wie Planungsflexibilität, Berechnungszeit u.a., als Grundlage für die Bestimmung des zu priorisierenden Fahrzeugs benutzt. Der aktuelle Pfad des priorisierten Prozessteilnehmers wird dann als final gesetzt und dieser Teilnehmer muss nicht mehr an den weiteren Planungen und Verhandlungen teilnehmen. Alle diese Informationen werden dann zwischen den kooperativen Fahrzeugen ausgetauscht, sodass jedes Fahrzeug feststellen kann, ob eine für alle Teilnehmer konfliktfreie Pfadkombination gefunden wurde. In diesem Fall ist das generelle Ziel des Algorithmus erreicht und er kann vorzeitig beendet werden. Ist dies nicht der Fall, kann jedes Fahrzeug bestimmen, welches Fahrzeug priorisiert behandelt werden soll und sich nicht weiter am Planungs- und Verhandlungsprozess beteiligt. Da die selbe Informationsgrundlage für diese Bestimmung vorhanden ist und sich jedes Fahrzeug an die Spielregeln hält wird genau ein Fahrzeug durch alle teilnehmenden Fahrzeug gleich als priorisiert bestimmt. Soweit keine konfliktfreie Pfadkombination gefunden wurde, wird für die verbleibenden teilnehmenden Fahrzeuge eine neue Iteration gestartet.

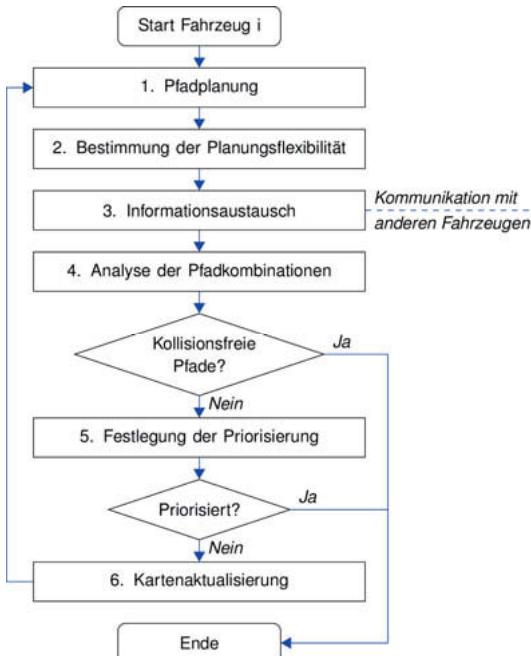


Bild 3: Ablaufdiagramm des Iterativen Priorisierungsverfahrens (IPV)

Im Folgenden werden die einzelnen Schritte ausführlicher erläutert.

**Schritt 1.** Zu Beginn jeder Iteration erzeugt jedes teilnehmende Fahrzeug mittels EA\* einen neuen Pfad unter Berücksichtigung der feststehenden dynamischen und statischen Hindernisse. Die zuvor von allen anderen Agenten gefundenen Pfade gelten als dynamische Hindernisse in der Umgebungskarte.

**Schritt 2.** Jedes Fahrzeug bestimmt seine Planungsflexibilität. Diese kann anhand der möglichen Bewegungsmanövern in den ersten Iterationen von EA\*, der Reisewegdauer und/oder durch die benötigte Berechnungszeit für EA\* bestimmt werden. Ziel dieser Flexibilitätsfeststellung ist die Generierung einer Entscheidungsgrundlage für die Priorisierung eines Fahrzeugs in einem späteren Schritt. Je unflexibler ein Fahrzeug seine Pfadplanung vollziehen kann, desto schneller sollte es priorisiert werden, um die Performance des Verhandlungsalgorithmus zu erhöhen.

**Schritt 3.** Der Informationsaustausch zwischen den Fahrzeugen wird durchgeführt. Die neu generierten Pfade und die Indizes für Planungsflexibilität werden ausgetauscht.

**Schritt 4.** Jedes Fahrzeug analysiert alle möglichen Pfadkombinationen, die nach dem Informationsaustausch möglich sind, ob eine konfliktfreie Pfadkombination existiert. Liegt eine solche vor, ist das generelle Ziel des Algorithmus erreicht und er endet. Falls nicht, folgt der Priorisierungsschritt.

**Schritt 5.** Hier wird festgelegt, welches Fahrzeug in der aktuellen Iteration priorisiert wird und nicht länger am Planungs- und Verhandlungsprozess teilnehmen muss. Dabei werden die in Schritt 2 bestimmten Planungsflexibilität herangezogen. Der zuletzt erzeugte Pfad des priorisierten Fahrzeugs wird als dessen endgültiger Pfad festgelegt. Da dieser Schritt von allen Fahrzeugen mit der gleichen Information deterministisch durchgeführt wird, ist keine weitere Kommunikation erforderlich. Aufgrund dieses Schrittes skaliert die Laufzeit des Algorithmus ohne Berücksichtigung von EA\* linear mit der Anzahl der teilnehmenden Fahrzeuge zu Beginn des Prozesses.

**Schritt 6.** Falls erforderlich, folgt auf das Priorisierungsverfahren die Kartenaktualisierung. In diesem Schritt werden die Informationen über neu erzeugte Pfade aller Fahrzeuge als dynamische Hindernisse in die Umgebungskarte jedes Fahrzeugs aufgenommen. Damit ist eine Iteration abgeschlossen und die nächste Iteration startet wieder mit Schritt 1.

### Simulationsergebnisse

Im Folgenden werden Simulationsergebnisse für das vorgestellte kooperative dezentrale Pfadplanungs- und Verhandlungssystem in zwei definierten Benchmark-Szenarien nach folgenden Kriterien bewertet: Gesamtfahrzeit  $t_T$  aller Fahrzeuge, Anzahl der Algorithmusiterationen  $n$ , gesamte Laufzeit des Algorithmus  $\sum t_R$  als Summe der Algorithmuslaufzeit  $t_R$  aller beteiligten Einheiten und maximale Laufzeit des Algorithmus  $t_R^{\max}$ .

#### **Erstes Testszenario: Freiraumszenario mit (dynamischen) Hindernissen**

In dem ersten Szenario wird ein Freiraumszenario, z.B. Parkplatz, mit fünf teilnehmenden automatisierten Fahrzeugen simuliert. In diesem Szenario planen vier autonome Fahrzeuge ihre Pfade zusammen, wobei sie die Aktionen der manuell betriebenen Einheit, deren Pfad in der oberen rechten Ecke endet, berücksichtigen. Abbildung 4 zeigt die initialen und die finalen Pfade. Ihre Startwaben sind mit Kreisen und Zielwaben mit Rauten entsprechender Farben markiert. Der Konflikt wird als graues Sechseck dargestellt. Die fette Linie markiert die Pfadabschnitte, die mit reduzierter Geschwindigkeit überquert wurden.

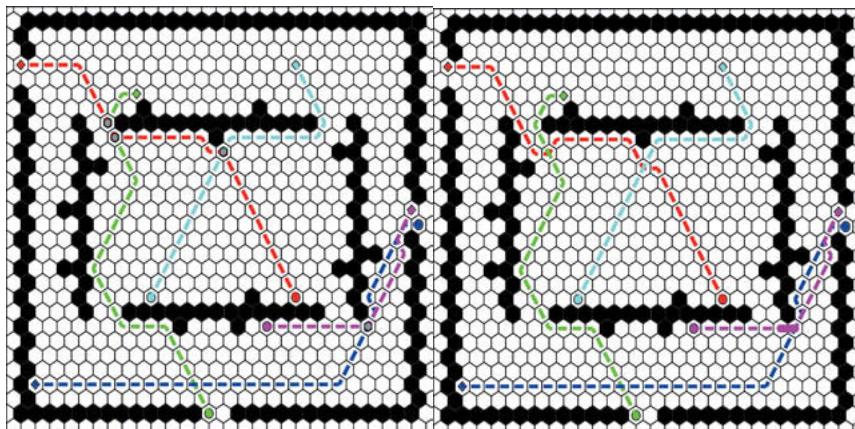


Bild 4: Kollisionsbehaftete (initiale, links) und kollisionsfreie (finale, rechts) Pfadplanung im Freiraumszenario mit dynamischem Hindernis. Graue Sechsecke stellen Kollisionen dar; dickere, durchgezogene Pfadpassagen sollen verlangsamt durchfahren werden.

#### **Zweites Testszenario: Flaschenhalssituation**

Das zweite Szenario ist ein herausforderndes Engpasszenario, in dem zehn Fahrzeuge ihre Pfade durch einen engen Spalt planen. Abbildung 5 zeigt die finalen Pfade. Diese Simulation kann als Worst-Case-Szenario interpretiert werden, da die Ausgangspositionen der Fahrzeuge so gewählt werden, dass anfänglich viele Konflikte auftreten, so dass mehrere Verhandlungsiterationen erforderlich sind. Ein weiterer Faktor ist der Platzmangel zwischen den teilnehmenden Fahrzeugen. Dieser Umstand erschwert den Planungsprozess zusätzlich. Es ist deutlich zu erkennen, dass der EA\*-Algorithmus Pfade liefert, die alle möglichen Optionen der Umwege sowie das Beschleunigen und Abbremsen enthalten, um Konflikte zu vermeiden.

## Quantitative Ergebnisse

Tabelle 1: Quantitative Simulationsergebnisse

	Freiraumsze- nario	Fla- schen- halssze- nario
$t_T$ in s	581	210
n	2	10
$\sum t_R$ in s	0,92	7,41
$t_R^{\max}$ in s	0,48	1,44

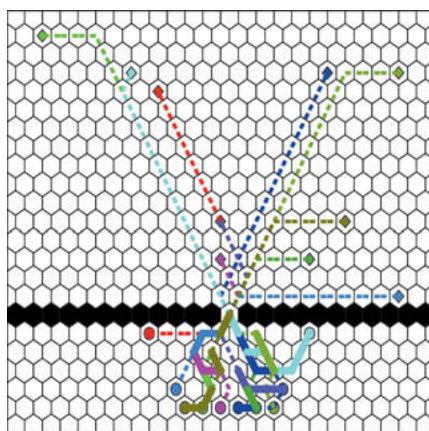


Bild 5: Kollisionsfreie, finale Pfadplanung im Flaschenhalsszenario. Dickere, durchgezogene Pfadpassagen sollen verlangsamt durchfahren werden.

## Diskussion

Die Simulationsergebnisse belegen die Fähigkeit des IPVs, in verschiedenen Situationen eine zulässige Lösung zu finden, selbst bei bestehenden Engpässen an Bewegungsmöglichkeiten zwischen Fahrzeugen, wie in der Flaschenhalssituation. Dieser Erfolg basiert auf der Fähigkeit des EA\*, alle verfügbaren Manöveroptionen zu nutzen, d.h. Geschwindigkeitsänderungen und Umwege, um Konflikte zu vermeiden. Der vorgestellte Pfadplanungsansatz ist auch in der

Hindernisse zu berücksichtigen. Darüber hinaus zeigt die Laufzeit des Algorithmus das Potenzial zur Online-Fähigkeit auf, die für eine schnelle Neuplanung und Reorganisation im Fall von falschen Bewegungsvorhersagen von manuell fahrenden Fahrzeugen oder anderen externen dynamischen Hindernissen, wie beispielsweise menschlichen Operatoren, erforderlich sind. Die Differenz zwischen  $\sum t_R$  und  $t_R^{max}$  -Werten verdeutlicht den Vorteil eines dezentralisierten Ansatzes durch die Einsparung von effektiver Laufzeit aufgrund der Verteilung der Arbeitslast.

## **Zusammenfassung**

In dieser Arbeit wird ein Konzept für die dezentrale kooperative Pfadplanung für Freiraumszenarien vorgestellt. Der Fokus liegt auf dem iterativen Priorisierungsverfahren (IPV). Der Ansatz kombiniert prioritätsbasierte Methoden mit der Bewertung von Pfadmerkmalen. Der resultierende Algorithmus reduziert die Anzahl der aktiv planenden Fahrzeuge in jeder Iteration um mindestens eins. Dies hat den Vorteil, dass die Anzahl der von jedem Planungsfahrzeug auszuwertenden Pfadkombinationen nicht mit der zunehmenden Anzahl von Iterationen exponentiell ansteigt, wie dies bei einigen Algorithmen nach dem Stand der Technik der Fall ist, siehe [4]. Grundlage des IPVs ist der vorgestellte graphenbasierte Pfadplanungsalgorithmus EA\*. Für den Geltungsbereich des EA\*-Algorithmus wird der grundlegende A\*-Ansatz durch Funktionen zur Geschwindigkeitsänderung von Fahrzeugen und zur Berücksichtigung dynamischer Hindernisse erweitert.

Zusammenfassend ist das vorgestellte Verfahren ein leistungsfähiges Werkzeug für die dezentrale kooperative Pfadplanung und Verhandlung in Freiraumszenarien im Kontext des Autonomen Fahrens. Es ist in der Lage, mit anderen mobilen Agenten wie manuell betriebenen Fahrzeugen oder anderen dynamischen Hindernissen wie menschlichen Operatoren umzugehen. Darüber hinaus verteilt das Verfahren die rechnerische Arbeitslast auf die teilnehmenden Fahrzeuge. Weitere Anwendungsbereiche finden sich im Kontext von Industrie 4.0-Szenarien und allgemein der Robotik.

## Literatur

- [1] van den Berg, J.P., Overmars, M.H.: Prioritized motion planning for multiple robots. IEEE/RSJ International Conference on Intelligent Robots and Systems 2005, S. 430-435.
- [2] Donges, E.: A conceptual framework for active safety in road traffic. Vehicle System Dynamics 32(2-3) 1999, S. 113-128.
- [3] During, M., Pascheka, P.: Cooperative decentralized decision making for conflict resolution among autonomous agents. IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA) Proceedings, IEEE 2014, S. 154 -161.
- [4] Frese, C.: Planung kooperativer Fahrmanöver für kognitive Automobile. Dissertation, Karlsruhe Institute of Technology (KIT) 2012.
- [5] LaValle, S.M.: Planning Algorithms. Cambridge University Press 2006.
- [6] Samek, J., Sislak, D., Volf, P., Pechoucek, M.: Multi-party collision avoidance among unmanned aerial vehicles. Intelligent Agent Technology, 2007. IAT '07. IEEE/WIC/ACM International Conference 2007, S. 403-406.
- [7] Tazaki, Y., Suzuki, T.: Multi-robot scheduling and trajectory planning using state roadmap. Proceedings of the SICE Annual Conference (SICE), IEEE 2014, S. 1272-1277.



# Echtzeitfähige Trajektoriengenerierung für hoch-automatisierte und autonome Fahrzeuge bei Zustands- und Stellgrößenbeschränkungen

**Steffen Joos,**

Robert Bosch GmbH, Abstatt/Renningen;

**Roktim Bruder, Thomas Specker, Matthias Bitzer,**

Robert Bosch GmbH, Renningen;

**Knut Graichen,**

Lehrstuhl für Automatisierungstechnik, Friedrich-Alexander Universität Erlangen-Nürnberg, Erlangen



## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Motivation



- Entwicklung automatisierter Fahrzeuge aktuelles Thema in Forschung & Industrie
  - Kernaufgabe: **Trajektorienplanung (TP)** für Fahrsituationen wie z.B. Kollisionsvermeidung, Spurwechsel
- 
- Herausforderungen in lokaler TP: Optimale TP in Echtzeit u.B.v. (priorisierten) Beschränkungen
  - State of the Art: Polynomansätze (⊕ geringer Berechnungsaufwand, ⊖ Optimalität, Beschränkungen)
  - Alternativ: Modellprädiktive Ansätze (MPC) (⊕ Optimalität, Beschränkungen, ⊖ hoher Rechenaufwand)
    - ⇒ Existierende Methoden können nicht allen Herausforderungen gleichzeitig gerecht werden
  - Ziel: Entwurf eines lokalen Trajektorienplaners, der die Vorteile der o.g. Ansätze kombiniert

## Online-Trajektorienplanung für automatisierte Fahrzeuge

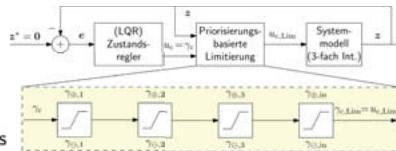
### Animationsvideo



## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Inhalt des Vortrags

1. Motivation
2. Problembeschreibung
3. Entwurf eines beschränkten Trajektorienplaners
  - (a) Herleitung zulässiger, flachheitsbasierter Grenzfunktionen
  - (b) Herleitung einer optimalen Schalt- bzw. Limitierungsstruktur
4. Simulationsbeispiele mit zeitdiskreter Implementierung des Planers
  - (a) Optimalitäts- und Rechenzeitvergleich mit MPC-Algorithmen
  - (b) Unlösbares Szenario & Einfluss der Priorisierungsreihenfolge
5. Zusammenfassung und Ausblick



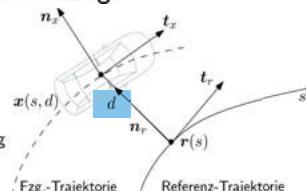
## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Problembeschreibung

- Planung der lokalen Trajektorie in Frenet-Koordinaten
  - Reduzierung des Fahrzeugs auf eine Punktmasse
  - Entkopplung lateraler und longitudinaler Fahrzeugbewegung
- Ziel: Stabilisiere Fahrzeug auf die Referenz  $\Rightarrow d(t) \rightarrow 0$
- Zulässige laterale Dynamik anhand **beschränktem 3-fach Integrator** mit  $z^T = [z_1 \ z_2 \ z_3] = [d \ \dot{d} \ \ddot{d}]$ 

$$\dot{z} = \underbrace{\begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}}_A z + \underbrace{\begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}}_b u, \quad z(t_0) = z_0 \quad \text{mit den Box-Beschränkungen:}$$

$$\begin{aligned} z_{1,\ominus} \leq z_1 \leq z_{1,\oplus} \\ z_{2,\ominus} \leq z_2 \leq z_{2,\oplus} \\ z_{3,\ominus} \leq z_3 \leq z_{3,\oplus} \\ u_{\ominus} \leq u \leq u_{\oplus} \end{aligned}$$
- Regelziel: Manipuliere den lateralen Ruck  $u = \ddot{d}$  so, dass u.B.v. den o.g. Beschränkungen  $d \rightarrow 0$



## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Kurzübersicht - Differentielle Flachheit für Eingrößenfall

- Parametrierung der Zustände sowie der Stell- und Ausgangsgröße in Abhängigkeit des flachen Ausgangs  $z$  und dessen zeitlichen Ableitungen  $z = [ z, \dot{z}, \dots, \overset{(n-1)}{\dot{z}} ]^T = [ z_1, z_2, \dots, z_n ]^T$ :

$$\mathbf{x} = \mathbf{T}^{-1} \cdot \mathbf{z}, \quad u = \dot{z}_n - t^T \cdot \mathbf{A}^n \cdot \mathbf{T}^{-1} \cdot \mathbf{z}, \quad y = \mathbf{c}^T \cdot \mathbf{T}^{-1} \cdot \mathbf{z}$$

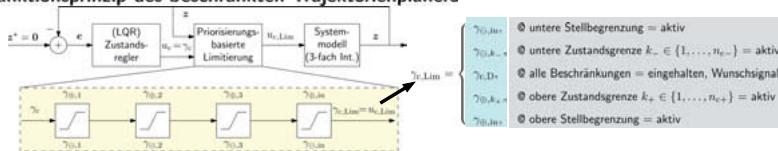
mit  $\mathbf{T} = [ t, \mathbf{A}^T \cdot t, \dots, (\mathbf{A}^T)^{n-1} \cdot t ]^T, t^T = [ 0, 0, \dots, 0, 1 ] \cdot \mathbf{Q}_S^{-1}$  und  $\mathbf{Q}_S = [ \mathbf{b}, \mathbf{A} \cdot \mathbf{b}, \dots, \mathbf{A}^{n-1} \cdot \mathbf{b} ]^T$

- Systemdarstellung in Regelungsnormalform  $\Rightarrow$   $n$ -fach Integratorkette gesteuert durch lineare Funktion
- Beschränkter 3-fach Integrator besitzt bereits Regelungsnormalform  $\Rightarrow$  o.g. Formeln vereinfachen sich zu

$$\mathbf{T} = \mathbf{I}, \quad \mathbf{x} = \mathbf{z}, \quad u = \dot{z}_3 (= \ddot{d} = \text{Ruck}), \quad y = z_1 (= d = \text{laterale Abweichung})$$

## Online-Trajektorienplanung für automatisierte Fahrzeuge

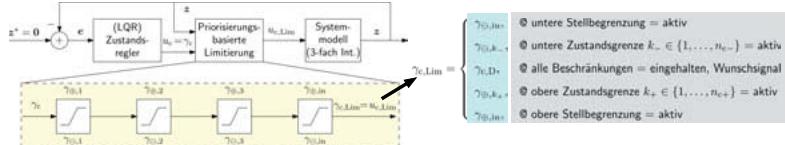
### Funktionsprinzip des beschränkten Trajektorienplaners



- Systemmodell in Regelungsnormalform  $\Rightarrow$  differentiell flach mit  $y = z_1 (= d = \text{lat. Abw.}), u = \dot{z}_3 (= \ddot{d} = \text{Ruck})$
- Systemstabilisierung unter Verwendung eines (unbeschränkten) LQR-Zustandsreglers  $u_c = -\mathbf{r}^T \mathbf{z}$
- Ziel:** Berücksichtigung von Beschränkungen durch Limitierung von  $u_c = \gamma_c$  [Joos et al. ECC'18]
  - Kaskade von Saturierungen mit Grenzfunktionen  $\gamma_{\Theta}, \gamma_{\Theta}$
  - Priorisierung von Beschränkungen durch Reihenfolge der Saturierungen / 'Schaltlogik'  $\Rightarrow$  problemspezifisch
  - Flachheitsbasierte Herleitung von **Grenzfunktionen** für jede Beschränkung so, dass Trajektorie die verfügbare Zustands- & Stellgrößenreserve ausnutzt  $\Rightarrow$  Planung der Trajektorie auf/entlang der Beschränkung

## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Herleitung zulässiger flachheitsbasierter Grenzfunktionen



- Entwurfschritte für optimale Limitierung des Integratorketteneingangs  $\gamma_{\ominus, \text{Lim}}$  [ Joos et al. ECC'18 ]:

1. Formulierung flachheitsbasierter unterer  $\gamma_{\ominus}$  und oberer  $\gamma_{\oplus}$  Grenzfunktionen für Integratorketteneingang  $\dot{z}_n$
2. Herleitung einer optimalen Schaltstruktur (Kaskade) ⇒ Ergebnis: (Schaltende) beschränkte lokale TP

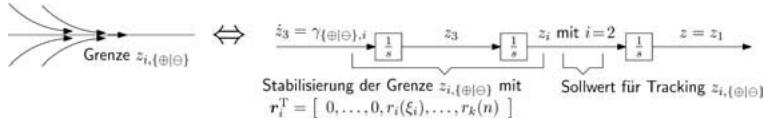
- **Stellbegrenzungen:** Grenzfunktionen  $\gamma_{\ominus, \text{in+}}, \gamma_{\ominus, \text{in-}}$  resultieren durch Einsetzen der Eingangsparametrierung

$$u_{\ominus} \leq u \leq u_{\oplus} \Rightarrow \gamma_{\ominus, \text{in}}(z) \leq \dot{z}_n \leq \gamma_{\oplus, \text{in}}(z) \text{ mit } \gamma_{\{\ominus\}, \text{in}[\oplus], \text{in}}(z) = t^T \cdot A^n \cdot T^{-1} \cdot z + u_{\{\ominus\}[\oplus]}$$

- Für das betrachtete System (3-fach Integrator) ergibt sich:  $\gamma_{\{\ominus\}, \text{in}[\oplus], \text{in}}(z) = u_{\{\ominus\}[\oplus]}$

## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Herleitung zulässiger flachheitsbasierter Grenzfunktionen



- **Box-Zustandsbeschränkungen** in flachen Koordinaten:  $|z_{i,\ominus} \leq z_i \leq z_{i,\oplus}|$  mit  $i = 1, \dots, 3$

- Zuweisung der Beschränkungen zu korresp. Integratorzustand  $z_i$  mit 'Index'  $\xi_i \Rightarrow \xi_i = i$  [ Joos et al. ECC'18 ]
- Idee: Auslegung von 3 oberen und unteren Grenzfunktionen in Form von Zustandsreglern

$$\gamma_{\{\ominus\}[\oplus], i} = -r_i^T \cdot z + z_{i, \{\ominus\}[\oplus]}$$

so, dass die Trajektorie  $z$  auf die bzw. entlang der Grenze  $z_{i, \{\ominus\}[\oplus]}$  gesteuert wird

## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Optimale Limitierungsstruktur & Priorisierung von Beschränkungen

- Limitierungsstruktur ergibt sich mit **skalarem Optimierungsproblem**

- **Resultat: Kaskade aus Saturierungselementen (SAT)**

- Implementierung von 1 SAT für Stellbegrenzungen und 3 SAT für die angenommenen Box-Zustandsbeschränkungen  $z_{i,\ominus} \leq z_i \leq z_{i,\oplus}$

- Limits der SAT eindeutig durch Grenzfunktionen  $\gamma_{\{\ominus|\oplus\},i}$  gegeben

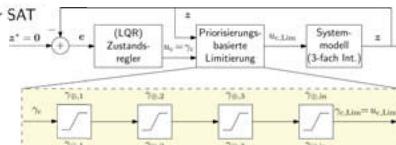
- **Priorisierung von Beschränkungen** über Reihenfolge der SAT

⇒ problemspezifischer Freiheitsgrad

⇒ signifikanter Einfluss auf generierte Trajektorie

⇒ erlaubt Behandlung unzulässiger Probleme

$$\begin{aligned} \gamma_{c,\text{Lim}}(t) = \underset{z_n}{\operatorname{argmin}} \quad & (\gamma_{c,D}(z, u_c) - \dot{z}_n)^2 \\ \text{w.r.t.} \quad & -\dot{z}_n + \gamma_{\ominus,k_-}(z, u_{p,k_-}) \leq 0, \forall k_- \\ & -\dot{z}_n + \gamma_{\oplus,\text{in}}(z, u_{\min}) \leq 0 \\ & \dot{z}_n - \gamma_{\oplus,k_+}(z, u_{p,k_+}) \leq 0, \forall k_+ \\ & \dot{z}_n - \gamma_{\oplus,\text{in}}(z, u_{\max}) \leq 0. \end{aligned}$$



## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Simulation Beispiel mit zeitdiskreter Implementierung des Planers

- Diskretisierung des Planerdynamik mit **zero-order-hold** und einer Schrittweite von  $\Delta t = 0.1\text{s}$

⇒  $u(t) = \text{const. } \forall t \in [t_i = i\Delta t, t_{i+1} = t_i + \Delta t]$

$$z(t_{i+1}) = A_D \cdot z(t_i) + b_D \cdot u(t_i) \quad \text{mit} \quad A_D = \begin{bmatrix} 1 & \Delta t & \Delta t^2/2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{bmatrix}, \quad b_D = \begin{bmatrix} \Delta t^3/6 \\ \Delta t^2/2 \\ \Delta t \end{bmatrix} \quad \text{und } i = 0, 1, \dots, i_{\max}$$

- Entwurf der Zustandsrückführung  $r$  mit MATLAB's `dlqr` und  $Q = I$  sowie  $R = 1$

- Beschränkungen:  $u_{\{\ominus|\oplus\}} = \mp 0.5 \frac{\text{m}}{\text{s}}$ ,  $z_{3,\{\ominus|\oplus\}} = \mp 0.2 \frac{\text{m}}{\text{s}}$ ,  $z_{2,\{\ominus|\oplus\}} = \mp 0.2 \frac{\text{m}}{\text{s}}$ ,  $z_{1,\{\ominus|\oplus\}} = \mp 0.75 \text{ m}$

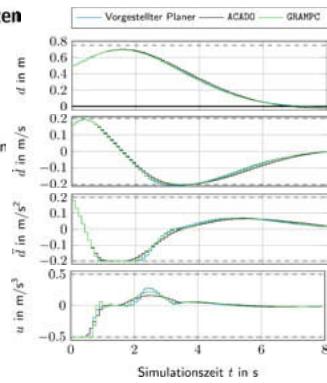
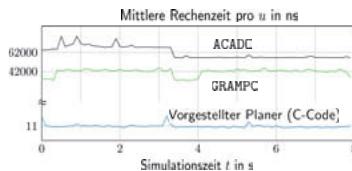
- Rückführungen  $r_i$  der Grenzfunktionen  $\gamma_{\{\ominus|\oplus\},i}$  mit Polplatzierung ⇒ Pole des geschlossenen Kreis gemäß

$r_1^T = r_2^T$	$r_3^T = r_4^T$	$r_5^T = r_6^T$
[7.9959, 8.0327, 3.9948]	[0, 8.3214, 4.1468]	[0, 0, 6.4934]
$\text{eig}(A_D - b_D \cdot r_1^T)$	$\text{eig}(A_D - b_D \cdot r_3^T)$	$\text{eig}(A_D - b_D \cdot r_5^T)$
0.8790 + 0.1598i	1	1
0.8790 - 0.1598i	0.7718 + 0.1765i	1
0.8009	0.7718 - 0.1765i	0.35066

## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Simulationsergebnisse und Vergleich mit MPC-Ansätzen

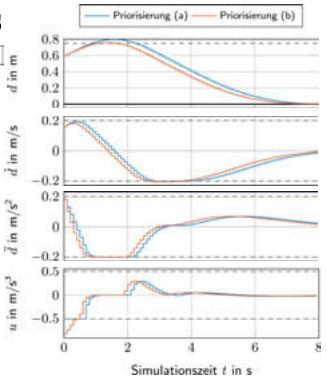
- Stabilisierung von  $z_0^T = [0.65 \text{ m} \ 0.16 \frac{\text{m}}{\text{s}} \ 0.18 \frac{\text{m}}{\text{s}^2}]$  in den Ursprung
- Beschränkungen (Priorität in der Reihenfolge, höchste zu geringste)  
 $u_{\{z\} \{z\}} = \mp 0.5 \frac{\text{m}}{\text{s}^3}$ ,  $z_3, \{z\} \{z\} = \mp 0.2 \frac{\text{m}}{\text{s}^2}$ ,  $z_2, \{z\} \{z\} = \mp 0.2 \frac{\text{m}}{\text{s}}$ ,  $z_1, \{z\} \{z\} = \mp 0.75 \text{ m}$
- Optimalitäts- & Rechenzeitvergleich mit zwei modernen MPC-Ansätzen
- MPC-Kosten:  $\min_{u(\cdot)} \int_{t_0}^{t_0+T_{\text{hor}}} z^T z + u^2 dt + z^T z|_{t_0+T_{\text{hor}}}$   
mit Prädiktionshorizont  $T_{\text{hor}} = 2 \text{ s}$  und  $0.1 \text{ s}$  diskreter Schrittweite



## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Simulationsergebnisse - Veränderung der Priorisierung

- Unlösbares Szenario: Stabilisierung von  $z_0^T = [0.65 \text{ m} \ 0.16 \frac{\text{m}}{\text{s}} \ 0.18 \frac{\text{m}}{\text{s}^2}]$
- Zwei verschiedene Priorisierungsreihenfolgen (höchste zu geringste)
  - (a) 1)  $u$ , 2)  $\dot{d}$ , 3)  $\ddot{d}$ , 4)  $d$   
 $\Rightarrow$  Positionsbeschränkung verletzt, Ruckbeschränkung eingehalten
  - (b) 1)  $d$ , 2)  $\dot{d}$ , 3)  $\ddot{d}$ , 4)  $u$   
 $\Rightarrow$  Ruckbeschränkung verletzt, Positionsbeschränkung eingehalten
- Signifikanter Einfluss der Priorisierungsreihenfolge auf die Trajektorie
- Funktionalität des Planers unabhängig von Lösbarkeit des Szenarios
- Online-Manipulation der Priorisierung z.B. mit Zustandsautomat



## Online-Trajektorienplanung für automatisierte Fahrzeuge

### Zusammenfassung

- ▶ Algorithmus zur beschränkten (lokalen) Trajektorienplanung für (laterale) Bewegung in Frenet-Koordinaten
- ▶ Ausnutzen der differentiellen Flachheit zur intuitiven Behandlung von Zustands- und Stellbeschränkungen
- ▶ Priorisierungsbasierter Ansatz: ⊕ Problemspezifisch anpassbar (Sicherheit vs. Komfort) und rekursionsfrei
  - ⊖ Potentielle, temporäre Verletzung von niedrig priorisierten Beschränkungen
- ▶ Geringer Online-Berechnungsaufwand und schlanke (zeitdiskrete) Implementierung

### Ausblick

- ▶ Implementierung & Anwendung des Planers auf dem Steuergerät eines prototypischen Fahrzeugdemonstrators
- ▶ Untersuchungen zur Kombination Planer & Zustandsautomaten zur Online-Manipulation der Priorisierung

# Review and experimental evaluation of models for drivability simulation with focus on tire modeling

## Short Version

**Korbinian Figel, Ferdinand Svaricek**, Bundeswehr University Munich;  
**Matthias Schultalbers**, IAV GmbH, Gifhorn

### Abstract

Recent research showed a significant role of the interaction between traction and torsional vibrations on control design in passenger cars. However, there is a large diversity in the proposed models for drivability control design and validation. This paper gives an overview of popular models in drivability simulation and addresses the quantitative evaluation of these models in a wide range of operating points. Experiments have been performed with diverse excitation signals. Based on these experiments, a number of popular models for control design and validation are identified and compared. A new model is proposed, which will be shown to be a good trade-off between model accuracy and complexity. The results give a guidance for control engineers during the model selection process for either controller concept design, parametrization or validation. This is a shortened version of the work published in [1].

### 1 Introduction

Automotive drivelines, either operated with electric drives or with combustion engines [2], tend to torsional vibrations during abrupt maneuvers. With increasing motor torque gradients, these vibrations get perceivable for the driver and are considered uncomfortable. These vibrations are often referred to as 'jerking' or 'shuffle' [3] and are in the focus of this work. They need to be distinguished from the tire induced power-hop phenomenon [4]. For example, when in the so-called Tip-In maneuver the accelerator pedal is pressed quickly, a step-like acceleration change is requested from the vehicle. This is translated in a motor torque by the motor control unit. A suitable motor management is able to modify the motor torque such that the requested change of acceleration is reached as fast as possible, while the perceivable driveline vibrations in the range from 0 Hz to 10 Hz (c.f. [5]) are reduced sufficiently. There are numerous studies on the model-based design of these so-called drivability controllers. However, the parametrization of the used control functions is still mostly done in laborious in-vehicle driving tests [6, 7].

Most of the studies focus on control design methods, based on linear time-invariant (LTI) models, identified at a single operating point [8, 3] or proving their method with a single experiment (e.g. [9]).

There is also a notable diversity in the complexity of the models ranging from a simple approximation of a second-order behavior [10] to a rather complex multi-body simulation model [11].

For that purpose, an experimental set-up has been built based on a mid-size plug-in hybrid electric vehicle (PHEV). In electric mode, the combustion engine and the flywheel are not attached to the driveline. Therefore, two main sources of nonlinearity are eliminated in this set-up and the role of the tires is emphasized in the experiments. Nevertheless, the investigated models can also be used for combustion engine cars, as long as a suitable engine model is coupled appropriately to the models used in this work. Tests have been performed in various driving situations and two different standard excitation signals for system identification (a chirp and a pseudo random multilevel signal (PRMS)). This paper is comparing the ability of the most popular models from literature (including the one in [12]) and a new model to simulate drivability-relevant vibrations in passenger cars. This study gives a guidance to control engineers for the selection of models for their individual purpose, such as control design, parametrization or validation.

In section 3, an overview of models for drivability simulation is given. In section 4, the experimental set-up is explained. and the parameter estimation method is described. The validation criteria are introduced in section 5: In addition to standard criteria for model validation, drivability-relevant measures are used to discuss the applicability of the models for comfort control design, optimization and validation. In section 6, the results of the quantitative model validation are shown and section 7 concludes the findings.

## 2 Symbols

$\dot{\cdot}$	Derivative with respect to time	$\varepsilon$	Residual
$\hat{\cdot}$	Estimated value	$\zeta$	Axle load ratio
$\bar{\cdot}$	Normalized value	$\theta$	Parameter set
$\tilde{\cdot}$	Physical parameter value	$\vartheta$	Torsion of drive-train
${}^{*0.5}$	Median of a value	$\vartheta_b$	Relative angle of contact planes
		$\vartheta_t$	Torsion of tire
$\alpha$	Average road elevation	$\mu$	Coefficient of traction
$\alpha_t$	Tire model parameter	$\rho_{air}$	Air density
$\beta_t$	Tire model parameter	$\tau$	Approximate normalized position in backlash
$\gamma_t$	Tire model parameter	$\sigma$	Longitudinal relaxation length
$\epsilon$	Slip		

$\varphi_m$	Motor angle	$c_{rr}$	Coefficient of rolling resistance
$\varphi_w$	Wheel angle	$c_{\text{slip}}$	Slip stiffness
$\omega_0$	Natural Frequency	$d$	Viscous damping factor of drivetrain
$\omega_m$	Rotational motor speed	$d_c$	Viscous damping factor of chassis
$\omega_t$	Rotational tire speed	$d_t$	Viscous damping factor of tyres
$\omega_w$	Rotational wheel speed		
$A_{\text{air}}$	Cross sectional area of vehicle	$f$	Cost function
$D$	Damping ratio	$g$	Gravitational acceleration
$F_\alpha$	Climbing resistance	$i_{\text{gears}}$	Overall gear ratio
$F_{\text{air}}$	Aerodynamic drag force	$k$	Stiffness coefficient of drivetrain
$F_{m,r}$	Resistance acting on vehicle mass	$k_c$	Stiffness coefficient of chassis
$F_t$	Traction force	$k_t$	Stiffness coefficient of tires
$F_{rr,f/r}$	Rolling resistance at front/rear wheel	$l_{f/r}$	Distance of center of front/rear wheel to COG in stand-still
$F_{w,z}$	Vertical wheel force	$m$	Vehicle mass
$F_x$	Longitudinal Force	$n$	Sampling instant
$J_m$	Motor-sided inertia	$n_p$	Sampling instant at peak
$J_r$	Inertia of two rims	$p$	Fitting parameter of $\tanh^2$
$J_t$	Inertia of two tires		backlash model
$J_{ts}$	Tire-sided inertia	$r$	Wheel radius
$J_w$	Inertia of two wheels	$s_{\text{rel}}$	Relative inertial position of the chassis to the car body
$J_{ws}$	Wheel-sided inertia		
$K_i$	Gain factors of LPV system	$t$	Time
$N$	Number of samples	$u$	Input vector in state-space system
$N_{\text{chirp}}$	Length of chirp signal	$v$	Inertial vehicle speed
$N_{\text{PRMS}}$	Length of PRMS signal	$v_c$	Inertial wheel and chassis speed
$N_{\text{sig}}$	Number of signals	$x$	State vector of state-space system
$T_m$	Motor torque	$y$	System output
$T_r$	Wheel resistance torque	$y$	Output vector from state-space system
$T_w$	Wheel torque	$y_c$	Second order characteristics
$a_{\text{rms}}$	Root mean squared value of acceleration		
$a_x$	Longitudinal acceleration	NRMSF	Normalised root mean square fit
$b$	Backlash angle	NMF	Normalised root mean square median fit
$b_{\text{fit}}$	Fit of simplified backlash model to ideal model at contact	RMF	Relative root mean square median fit
$c_d$	Drag coefficient	RAE	Relative error of $a_{\text{rms}}$

**Table 1.** Overview of models with and without backlash (BL) and their usage in the literature.

Model	Inertias	Masses	Tire model	Slip model	Literature w. BL	Literature w/o BL
Model A	2	0	Ideal	-	[6, 9]	[3, 6, 8]
Model B.1	2	1	Rigid	static, linear	-	[13, 14]
Model B.2	2	1	Rigid	static, nonlinear	-	[12, 15]
Model B.3	2	1	Rigid	dyn., linear	-	[13]
Model C.1	3	0	Elastic	-	[16, 17]	[3]
Model C.2	3	1	Elastic	static, linear	-	[18]
Model D.1	2	2	Rigid	static, linear	-	-
Model D.2	2	2	Rigid	static, nonlinear	-	-

### 3 Overview of models for drivability simulation

In this section, several models, selected from literature, are introduced. Physically motivated grey box models<sup>1</sup> are chosen because the number of parameters is minimal [19] and the model behavior can also be transferred to similar vehicle configurations such as a successor car or model derivatives. A bottom-up approach has been chosen: Starting from a rotational two inertias model, the model is augmented by additional elements. A very important aspect of this research is the investigation of the influence of certain elements on the capacity to simulate the drivability-relevant response of a vehicle. Thus, the additional elements are taken from literature and are added step-by-step to the complete model. Consequently the compared vehicle models are similar to existing models in the literature, but not all examined vehicle models have already been presented in exactly the same structure. An overview of the presented models and their usage in the literature is given in Table 1.

#### 3.1 Driving resistances

Nonlinear models depend on the absolute value of the acting torque. Hence, static forces and torques have to be considered during nonlinear system identification. These quantities are basically the driving resistances [20, p. 35 (et seq.)]: The rolling resistance  $F_{rr}$ , the aerodynamic drag force  $F_{air}$  and the climbing resistance  $F_\alpha$

$$F_{rr} = c_{rr} m g \cos(\alpha), \quad (1)$$

$$F_\alpha = m g \sin(\alpha), \quad (2)$$

$$F_{air} = c_d A_{air} \frac{\rho_{air}}{2} v^2. \quad (3)$$

<sup>1</sup>All models have been implemented by physical modeling techniques in Simscape<sup>TM</sup>.

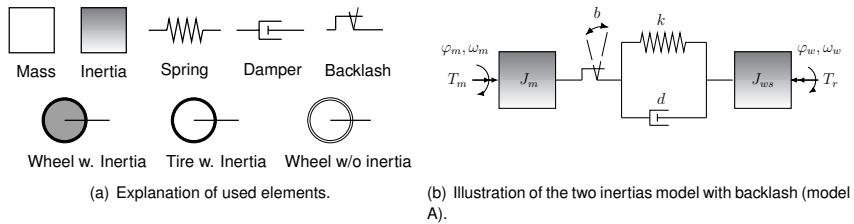


Figure 1. Illustration of model A and explanation of the elements.

The parameter  $\alpha$  is the road inclination,  $c_{rr}$  is the coefficient of rolling friction,  $\rho$  is the density of the air,  $A_{\text{air}}$  is the cross sectional area and  $c_d$  is the drag coefficient. The rolling resistance acts on the front ( $F_{rr,f}$ ) and the rear wheels ( $F_{rr,r}$ ). In contrast, the aerodynamic drag and the climbing resistance act on the vehicle mass and can be merged  $F_{m,r} = F_{\text{air}} + F_{\alpha}$ .

### 3.2 Backlash model

Backlash handling is crucial for a good performance of drivability controllers [21, 22, 23]. Popular models are the so-called "dead-zone model" [21, 24] or a more physical model of an idealized backlash [24]. These hybrid models of elastic systems with backlash are non-smooth and therefore challenging to handle in control design and simulation [25, p. 241]. Moreover, oil between mated gear teeth can transmit torque even in the backlash region. In [26] a smooth approximation is proposed:

$$T_{\text{tanh}} = k \left( \vartheta - \frac{b}{2} \tau \right) + d \dot{\tau}, \quad (4)$$

$$\tau = \tanh \left( \frac{2 \operatorname{atanh}(b_{\text{fit}})}{b} \vartheta \right). \quad (5)$$

The parameters  $k$  and  $d$  are the stiffness and damping coefficients of the drivetrain. The backlash parameters are its size  $b$  and  $b_{\text{fit}}$ , being the fit to an exact, non-smooth dead-zone model at  $\vartheta = \frac{b}{2}$  and damping  $d = 0$ . The variable  $\tau$  approximates the normalized angle with respect to the backlash size. A value of  $\tau \rightarrow 1/-1$  indicates that the gears are in contact.

### 3.3 Model A: Two inertias model with backlash

Starting point for all models is the popular two inertias model. It is a linear time-invariant (LTI) model and was used in many publications (c.f. Table 1). An illustration of the structure is shown in Fig. 1(b). It is a single-track model with ideally rolling wheels (slip-free). Consequently, the

relationship between the vehicle speed  $v$ , the angular wheel speed  $\omega_w$  and the wheel radius  $r$  is kinematic

$$v = \omega_w r. \quad (6)$$

This is used to map the translational inertia of the vehicle mass  $m$  into a simultaneous rotational motion with the front and rear wheels (with an overall inertia of  $2J_w$ ):

$$J_{ws} = 2J_w + m r^2. \quad (7)$$

The parameters of the model are the motor-sided inertia  $J_m$ , the wheel-sided inertia  $J_{ws}$ , the spring stiffness  $k$  and the viscous damping factor  $d$ . The states of the system are the torsion of the driveline  $\vartheta = \vartheta_w - \varphi_m$  and the angular velocities of the motor  $\omega_m = \dot{\varphi}_m$  and the wheels  $\omega_w = \dot{\varphi}_w$ . Input to the system is the motor torque  $T_m$  and the resistance torque  $T_r$ . With (5), the system of differential equations can then be formulated:

$$\dot{\vartheta} = \dot{\varphi}_w - \dot{\varphi}_m \quad (8a)$$

$$J_m \dot{\varphi}_m = k \left( 1 - \frac{b\tau}{2\vartheta} \right) \vartheta + d \dot{\vartheta} + T_m \quad (8b)$$

$$J_{ws} \dot{\varphi}_w = -k \left( 1 - \frac{b\tau}{2\vartheta} \right) \vartheta - d \dot{\vartheta} - T_r \quad (8c)$$

In this model, the resistances act accumulated on the wheel-sided inertias

$$T_r = (F_{m,r} + F_{rr,r} + F_{rr,f}) r. \quad (9)$$

The vehicle acceleration  $a_x$  follows from (6)

$$a_x = \frac{1}{m} F_x = \frac{1}{m r} T_w \quad (10)$$

and the wheel torque  $T_w$  is equal to the reaction torque of the elasticity:

$$T_w = J_{ws} \dot{\varphi}_w. \quad (11)$$

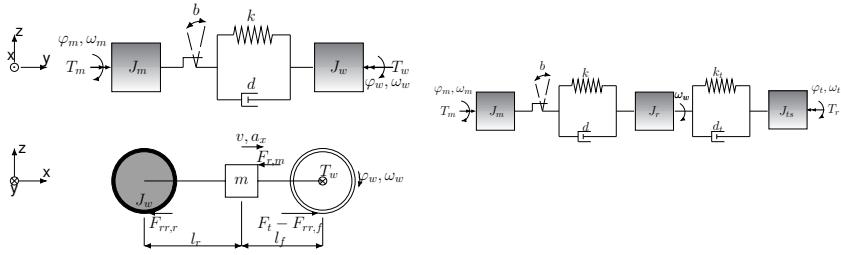
This model can also be used for drivelines with transmissions. Given, that the main elasticity of the drive train is in the drive shafts (c.f. e.g. [18]), all gearboxes are located between the motor-sided inertia and the elasticity. The physical properties  $\tilde{T}_m$ ,  $\tilde{\omega}_m$  and  $\tilde{J}_m$  can be transformed into equivalent values in the system without gear ratios (cf. equation (8)) [27]. Taking the overall gear ratio of the

driveline  $i_{\text{gears}}$  into account, the model parameters can be determined by

$$T_m = i_{\text{gears}} \tilde{T}_m, \quad \omega_m = \frac{1}{i_{\text{gears}}} \tilde{\omega}_m, \quad J_m = i_{\text{gears}}^2 \tilde{J}_m. \quad (12)$$

This relation is also valid for all other models presented in this work.

### 3.4 Model B.1: Coupled model with linear traction curve and backlash



(a) Illustration of the two inertias model with backlash and (b) illustration of the three inertias model with backlash (model B.1-B.3).

Figure 2. Illustration of model B.1-C.2

In order to introduce more detailed traction characteristics, the system is divided into a rotational and a translational system (cf. Fig. 2(a)). The rotational system is similar to system (8), but the wheel sided inertia is reduced to the inertia of the driven wheels. The resistances are distributed to their physical location of attack. The rotational system can be formulated as follows:

$$\dot{\vartheta} = \dot{\varphi}_w - \dot{\varphi}_m \quad (13a)$$

$$J_m \dot{\varphi}_m = k \left( 1 - \frac{b \tau}{2 \vartheta} \right) \vartheta + d \dot{\vartheta} + T_m \quad (13b)$$

$$J_w \dot{\varphi}_w = -k \left( 1 - \frac{b \tau}{2 \vartheta} \right) \vartheta - d \dot{\vartheta} - T_w. \quad (13c)$$

The wheel torque  $T_w$  is connecting both systems and is inducing a traction force  $F_t$

$$T_w = (F_t - F_{rr,f}) r, \quad F_t = \mu(\epsilon) F_{w,z}, \quad F_{w,z} = \zeta mg. \quad (14)$$

The vertical wheel load  $F_{w,z}$  is defined by the vehicle mass and the axle load distribution

$$\zeta = \frac{l_r}{l_f + l_r}. \quad (15)$$

The parameters  $l_f$  and  $l_r$  are the distance of the center of the front/rear wheel to the center of gravity (COG) of the vehicle in stand-still. The wheel radius  $r$  is assumed to be constant, whereas the traction force coefficient  $\mu$  depends on the wheel slip  $\epsilon$ . In this work the slip definition of [28] is used.

$$\epsilon(\omega_w, v) = \begin{cases} \frac{r\omega_w - v}{v} & : r\omega_w < v \quad (\text{braking}) \\ \frac{r\omega_w - v}{r\omega_w} & : r\omega_w > v \quad (\text{driving}) \end{cases} \quad (16)$$

The suspensions are modeled rigid. Hence, the vehicle's longitudinal motion results directly from Newton's second law:

$$a_x = \dot{v} = \frac{F_t - F_{rr,f} - F_{rr,r} - F_{r,m}}{m} = \quad (17)$$

$$\mu(\epsilon) \zeta g - \frac{F_{rr,f} + F_{rr,r} + F_{r,m}}{m}. \quad (18)$$

As a first step, a traction model with a linear relation between the traction force coefficient  $\mu$  and the slip  $\epsilon$  is introduced:

$$\mu(\epsilon) = c_{\text{slip}} \epsilon. \quad (19)$$

This model is used in [29] without backlash.

### 3.5 Model B.2: Coupled model with nonlinear traction curve and backlash

This model is similar to the model in [12] (with additional backlash) and is augmenting model B.1 by a nonlinear definition of traction

$$\mu(\epsilon) = \alpha_t \tanh(\beta_t \epsilon) \left( e^{-\gamma_t |\epsilon|} + 1 \right), \quad (20)$$

with the fitting parameters  $\alpha_t$ ,  $\beta_t$  and  $\gamma_t$ .

### 3.6 Model B.3: Coupled model with backlash and slip dynamics

Another augmentation of model B.1 is the incorporation of first-order slip dynamics. Adapting [30, eq. (12)] from braking to driving situations yields

$$\sigma \frac{d}{dt} \epsilon + r \omega_w \epsilon = r \omega_w - v, \quad (21)$$

with  $\sigma$  being the longitudinal relaxation length of the tire. A similar model has been investigated in [13]. The traction is defined by (19) in this work.

### 3.7 Model C.1: Three inertias model with backlash

As described in section 1, some authors are taking another elasticity (but no tire slip) into account (c.f. [16, 3]). With the introduction of an additional elasticity, the system (8) is augmented by two states: The rotational tire speed  $\omega_t$  and the torsion of the tire  $\vartheta_t$ . For this model,  $\omega_w$  denotes the rim speed and  $\vartheta$  the torsion of the parts between the motor and the rims. The resistance torque  $T_r$  is defined in (9). The system of differential equations can then be formulated as follows:

$$\dot{\vartheta} = \omega_w - \omega_m \quad (22a)$$

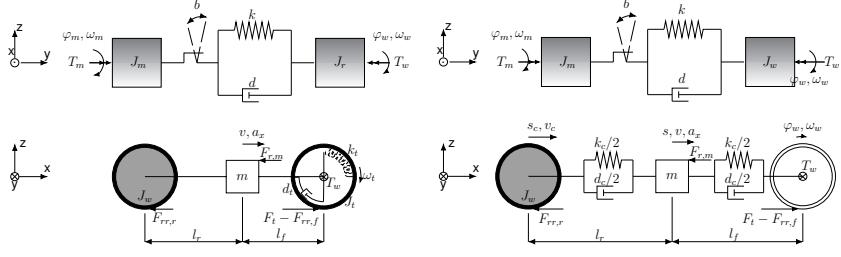
$$\dot{\vartheta}_t = \omega_t - \omega_w \quad (22b)$$

$$J_m \dot{\omega}_m = k \left( 1 - \frac{b\tau}{2\vartheta} \right) \vartheta + d \dot{\vartheta} + T_m \quad (22c)$$

$$J_w \dot{\omega}_w = -k \left( 1 - \frac{b\tau}{2\vartheta} \right) \vartheta - d \dot{\vartheta} + k_t \vartheta_t + d_t \dot{\vartheta}_t \quad (22d)$$

$$J_{ts} \dot{\omega}_t = -k_t \vartheta_t - d_t \dot{\vartheta}_t - T_r. \quad (22e)$$

### 3.8 Model C.2: Coupled model with backlash, rigid ring tire model and linear traction curve



(a) Illustration of the coupled model with backlash, rigid ring tire model and linear traction curve (model C.2). (b) Illustration of the Coupled model with backlash, traction curve and translational elasticity (model D.1 and D.2).

Figure 3. Illustration of model C.2, D.1 and D.2.

In addition to the tire dynamics in model C.1, slip is considered in [31, 13, 18]. In contrast to [31, 13], the linear  $\mu - \epsilon$  relation (19) is used here. Furthermore, the backlash model differs from these works. The system equations are

$$\dot{\vartheta}_t = \omega_t - \omega_w \quad (23a)$$

$$\dot{\vartheta} = \dot{\varphi}_w - \dot{\varphi}_m \quad (23b)$$

$$J_m \dot{\omega}_m = k \left( 1 - \frac{b \tau}{2 \vartheta} \right) \vartheta + d \dot{\vartheta} + T_m \quad (23c)$$

$$J_w \dot{\omega}_w = -k \left( 1 - \frac{b \tau}{2 \vartheta} \right) \vartheta - d \dot{\vartheta} + k_t \vartheta_t + d_t \dot{\vartheta}_t \quad (23d)$$

$$J_t \dot{\omega}_t = -k_t \vartheta_t - d_t \dot{\vartheta}_t - (F_t - F_{rr,f}) r \quad (23e)$$

$$\dot{v} = \frac{1}{m} (F_t - F_{rr,f} - F_{rr,r} - F_{r,m}) \quad (23f)$$

### 3.9 Model D.1 and D.2: Coupled model with backlash, (non)linear traction curve and translational elasticity

In section 6, it will be shown, that the introduced tire elasticity in model C.2 is improving the overall accuracy of the model. However, the acceleration magnitudes are underestimated. Thus, the elasticity is shifted to the longitudinal motion. The authors in [18, 29] also model this degree of freedom (DOF). However, the models in these works include even more DOFs and are consequently challenging to parametrize. In contrast, this model consists of the third-order driveline model (13) and

- the tire model with linear traction curve defined by (14) to (16) and (19) (model D.1) or
- the tire model with nonlinear traction curve defined by (14) to (16) and (20) (model D.2).

Therefore, the model is a trade-off between the accuracy of the models in [18, 29] and a reasonable identification effort. The translational dynamics of the car is depending on the chassis/wheel inertial position  $s_c$  and its velocity  $v_c$ . All wheels share the vehicle's main velocity, while the car body moves with velocity  $v$ . The relative inertial position of the chassis to the car body is  $s_{rel}$ . The system can be formulated as follows:

$$\dot{\vartheta} = \dot{\varphi}_w - \dot{\varphi}_m \quad (24a)$$

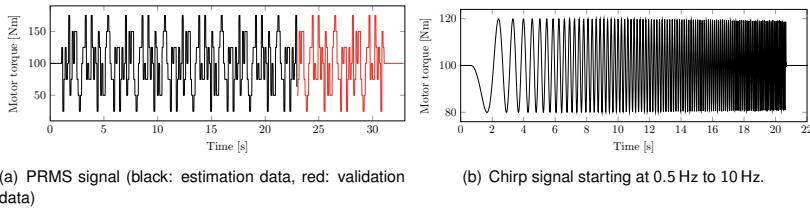
$$J_m \dot{\omega}_m = k \left( 1 - \frac{b \tau}{2 \vartheta} \right) \vartheta + d \dot{\vartheta} + T_m \quad (24b)$$

$$J_w \dot{\omega}_w = -k \left( 1 - \frac{b \tau}{2 \vartheta} \right) \vartheta - d \dot{\vartheta} - T_w. \quad (24c)$$

$$\dot{s}_{rel} = v - v_c \quad (24d)$$

$$\frac{1}{r^2} J_w \dot{v}_c = k_c s_{rel} + d_c \dot{s}_{rel} + F_t - F_{rr,f} - F_{rr,r} \quad (24e)$$

$$m \dot{v} = -k_c s_{rel} - d_c \dot{s}_{rel} - F_{r,m}. \quad (24f)$$



(a) PRMS signal (black: estimation data, red: validation data)

(b) Chirp signal starting at 0.5 Hz to 10 Hz.

**Figure 4.** Excitation signals.

## 4 Experiments and Parameter estimation

A main objective of this research is to investigate the role of the tire on longitudinal vehicle vibrations. The experiments had to be performed in driving tests as test-rigs often induce additional dynamics, which perturb the result [32]. A series production PHEV has been operated in electric mode and was additionally equipped with an inertial measurement unit at the co-drivers seat rail and wheel sensors for the wheel forces and torques. More details on the hardware and on the signal processing can be found in [1].

### 4.1 Maneuvers for identification

In order to guarantee the validity of models and parameter sets, the system has to be excited by a signal rich in frequency content in a wide range of operating points. In [33], it has been shown that the system depends also on the amplitude of excitation. A chirp guarantees an equal excitation of all frequencies in the band of interest (cf. Fig. 4(b)). However, the resonance frequency is excited only for a short period of time. Hence, the resonance occurs in a small velocity range. A PRMS consists of many short steps with varying step height (cf. Fig. 4(a)). This ensures the excitation of longitudinal effects [34] and the excitation of a wide range of frequencies at any time and velocity. An additional offset is preventing the system from crossing the backlash. The offset is also accelerating the vehicle and ensures that the necessary velocity range is traversed.

### 4.2 Parameter estimation method

The objective of this work is to compare the most popular models in the literature. For a valid comparison, a good estimation of the model parameters is crucial. The tire radius, the wheel load and the overall backlash size have been determined directly from the car in stand-still. The driving resistance coefficients have been estimated from coast down tests and the overall gear ratios from

constant travel tests. All other parameters have to be estimated from dynamic experiments. The estimation is done by a least squares fitting procedure of the wheel torque  $T_w$ , the bandpass-filtered rotational motor speed  $\omega_w$ , the torsional speed of the driveline  $\dot{\vartheta}$  and the acceleration  $a_x$ , resulting in  $\mathbf{y} = [T_w, \omega_w, \dot{\vartheta}, a_x]$ . Input to the system is the motor torque<sup>2</sup>  $T_m$ .

The used cost function  $f(\hat{\theta})$  is based on the residuals  $\varepsilon[n, \hat{\theta}]$ , being the difference between the reference data  $\mathbf{y}[n]$  and the simulated data  $\hat{\mathbf{y}}[n, \hat{\theta}]$  at sample instant  $n$  for the parameter set  $\hat{\theta}$ . The residual of output signal  $y_i$  is

$$\varepsilon_i[n, \hat{\theta}] = y_i[n] - \hat{y}_i[n, \hat{\theta}]. \quad (25)$$

In order to eliminate the influence of the individual scales of the output signals, the residuals are normalized by their maximum reference value

$$\bar{\varepsilon}_i[n, \hat{\theta}] = \frac{y_i[n] - \hat{y}_i[n, \hat{\theta}]}{\max_n (y_i[n])}. \quad (26)$$

The most important characteristic of a dynamic system is the resonance frequency. The response to a chirp signal has a clear peak at resonance (sample instant  $n_p$ ). Hence, this period must be fitted with high priority. Thus, the residuals of the chirp are weighted with a Gaussian function

$$w_{\text{chirp}}[n] = e^{\frac{-(n-n_p)^2}{2(0.15N)^2}} \quad (27)$$

with the mean location at  $n_p$  and a standard deviation of 15% of the chirp signal length  $N_{\text{chirp}}$ . The residuals of the PRMS experiment are not weighted and the sum of squares of both experiments are added. With the number of fitted signals  $N_{\text{sigs}}$ , the cost function  $f(\hat{\theta})$  can be formulated

$$f(\hat{\theta}) = \sum_{n=1}^{N_{\text{chirp}}} \sum_{i=1}^{N_{\text{sigs}}} (w_{\text{chirp}}[n] \cdot \bar{\varepsilon}_{i, \text{chirp}}[n, \hat{\theta}])^2 + \dots \\ \dots + \sum_{n=1}^{0.7 \cdot N_{\text{PRMS}}} \sum_{i=1}^{N_{\text{sigs}}} \bar{\varepsilon}_{i, \text{PRMS}}[n, \hat{\theta}]^2. \quad (28)$$

For estimation, 70% of the PRMS signal length  $N_{\text{PRMS}}$  is used, while the rest of the signal is used for cross-validation of the estimates (c.f. Figure 4). This is not possible for the chirp signal, because the resonance occurs in a short time interval. Hence, a second chirp experiment is used for cross-validation.

<sup>2</sup>The motor torque has been estimated from electrical quantities. The estimator cannot be presented, due to confidentiality reasons.

There are efficient solvers for this nonlinear least-squares problem, but these solvers are searching for local minima. In contrast, global solvers are able to find global minima, but are computationally expensive. Consequently, a rough global optimization has been used to find a good starting point for a thorough local parameter estimation:

1. **Global estimation:** The parameters are estimated by a Pattern Search algorithm using a latin hypercube search method<sup>3</sup>. Additionally, the road inclination is estimated for the two experiments separately.
2. **Local estimation refinement:** The parameter set is refined by the gradient-based nonlinear least-squares algorithm Trust-Region-Reflective<sup>3</sup> (cf. [35]).

## 5 Validation and evaluation criteria

In order to give a guidance for control engineers for the selection of an appropriate model for their purpose, the models are evaluated by several criteria.

A models' ability to reproduce input-output data for a parameters set  $\hat{\theta}$ , can be expressed by the residuals  $\varepsilon$  (cf. (25)). They are used in the popular Normalized Root Mean Squared Fit (NRMSF) which is computed for each output signal  $y_i$  separately

$$\text{NRMSF}_i(\hat{\theta}) = 1 - \frac{\sqrt{\sum_{n=1}^N \varepsilon_i^2[n, \hat{\theta}]}}{\sqrt{\sum_{n=1}^N (y_i[n] - \text{mean}(y_i))^2}}. \quad (29)$$

This criterion varies between  $-\infty$  (bad fit) and 1 (perfect fit). If the value is equal to zero, then the model is no better at fitting the measured data than a straight line equal to the mean of the data [36]. Based on our experience in control design, a NRMSF of 0.7 is the threshold for models to be suitable for control design.

The shown criterion is a standard tool in system identification and suitable for general model evaluation. However, its definition is not taking the specific requirements for drivability evaluation into account. Therefore, an additional criterion is introduced for the passengers' comfort perception rating. The root mean squared (RMS) value of the detrended frequency weighted acceleration  $a_{\text{rms}}$  is standard to describe the human response to vibration [1, 5]. For a quantitative model evaluation, the

---

<sup>3</sup>These algorithms are implemented in Mathwork's Simulink Optimization and global Optimization Toolbox<sup>TM</sup> and 100 sampling points have been used

relative error of this value (RAE) is computed:

$$\text{RAE}(\hat{\vartheta}) = \frac{\hat{a}_{\text{rms}}(\hat{\vartheta}) - a_{\text{rms}}}{a_{\text{rms}}}. \quad (30)$$

Two additional criteria are introduced that validate the fit of the model characteristics to the results of the experiments in [33]. In these experiments, the second order characteristics of the same test vehicle has been identified in a wide velocity range. Both criteria are a normalized root mean square value based on the second-order characteristics  $y_c$  (natural frequency or damping ratio) of the models. In order to ensure comparability, the simulated signals are analyzed with the same method as the experiments in [33]. The reference value is the median of the experimentally determined characteristics at distinct driving speeds  $\hat{y}_{c,0.5} [n_v]$ .  $N_v$  is the total number of operating points, whereas  $n_v$  indicates a distinct operating point.

The normalized root mean square median fit NMF gives the cumulated proximity of the model's natural frequency (or its damping ratio) to  $\hat{y}_{c,0.5} [n_v]$ . It ranges from  $-\infty$  to 1, with 1 denoting a perfect fit. If the value is equal to zero, then the model is no better at fitting the modal characteristics than a linear model with second-order characteristics equal to the estimated mean values.

$$\text{NMF}(\hat{\vartheta}) = 1 - \frac{\sqrt{\sum_{n_v=1}^{N_v} (y_c [n_v] - \hat{y}_{c,0.5} [n_v])^2}}{\sqrt{\sum_{n_v=1}^{N_v} \left( \hat{y}_{c,0.5} [n_v] - \text{mean}_{n_v}(\hat{y}_{c,0.5} [n_v]) \right)^2}} \quad (31)$$

This NMF is normalizing with focus on the comparison to a linear model. However, it is not taking the absolute reference value into account. Therefore, the Relative Root Mean Square Median Fit (RMF) is defined:

$$\text{RMF}(\hat{\vartheta}) = 1 - \frac{\sqrt{\sum_{n_v=1}^{N_v} (y_c [n_v] - \hat{y}_{c,0.5} [n_v])^2}}{\sqrt{\sum_{n_v=1}^{N_v} (\hat{y}_{c,0.5} [n_v])^2}}. \quad (32)$$

Again, it ranges from  $-\infty$  to 1, with 1 being the perfect fit.

## 6 Results

The evaluated results of the parameter estimation are presented in Table 2. The table shows the averaged NRMSF value for all output signals  $y$  and the NRMSF value of the acceleration signal. The acceleration signal is picked out because the drivability evaluation is based on this signal. In addition, the RAE is shown. The number of parameters  $n_\theta$  is given as a criterion for the model

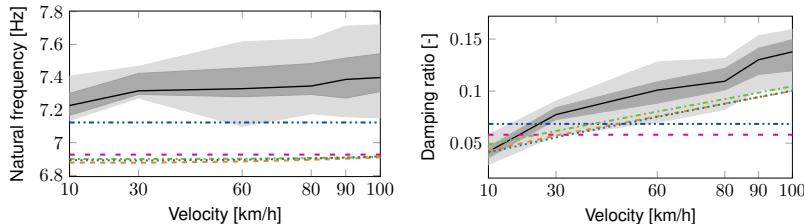
**Table 2.** Validation of candidate models in third gear

		mean				mean			
		NRMSF	$a_x$	RMSE	$n_\theta$	NRMSF	$a_x$	RMSE	$n_\theta$
		[%]	[%]	[%]		[%]	[%]	[%]	
Chirp (est)	A	68	61	-22		74	71	-13	
Chirp (val)		69	59	-25	7	75	68	-17	9
PRMS (est)		70	64	-12		76	68	-8	
PRMS (val)		72	71	-4		70	70	2	
Chirp (est)	B.1	70	58	-25		79	70	-16	
Chirp (val)		70	55	-29	10	78	65	-20	13
PRMS (est)		72	64	-11		79	70	-5	
PRMS (val)		78	65	-7		76	62	-1	
Chirp (est)	B.2	71	58	-25		81	73	-12	
Chirp (val)		70	54	-30	12	80	68	-17	12
PRMS (est)		72	64	-11		80	70	-3	
PRMS (val)		78	66	-7		79	64	-1	
Chirp (est)	B.3	72	58	-26		81	73	-12	
Chirp (val)		70	54	-30	11	79	68	-17	14
PRMS (est)		75	64	-12		80	71	-3	
PRMS (val)		77	60	-10		79	64	-1	
D.1									
D.2									

complexity. The estimated parameter values can be found in [1]. The estimation of model A has an average NRMSF of 68%/70% for the chirp/PRMS experiment. For linear control design methods, this could already be an acceptable fit. With 69%/72% NRMSF, the validation data are reproduced similarly. However, the important acceleration signal is fitted almost 10% points worse (except the PRMS validation data). This is also highlighted by the rather large RAE values of 22%/12% for the estimation signals.

The introduction of a linear static  $\mu - \epsilon$  relation (model B.1) is improving the average NRMSF of the estimation data by 2% points, while the NRMSF of  $a_x$  is worse. The improvement of a nonlinear  $\mu - \epsilon$  (model B.2) is not noteworthy, but the introduction of first-order tire dynamics (model B.3) does improve the NRMSF by another 2 – 3%. However, the fit of  $a_x$  and the RAE is still on the level of model A. In contrast, second-order tire dynamics (model C.1) improve the NRMSF of the  $a_x$  estimation data clearly by 13%/4% points for the chirp/PRMS. The average NRMSF of 74%/76% for model C.1 is a significant improvement as well. The introduction of the linear static  $\mu - \epsilon$  relation improves the average fit by another 3 – 5% for the estimation experiments. However, the fit to the acceleration deteriorates. In almost all cases, the RAE is negative. Hence, the acceleration magnitude is underestimated with all models.

The longitudinal elasticity in model D.1 remedies this drawback as the RAE is below 5% for the



(a) Validation of the velocity trend of the natural frequency. (b) Validation of the velocity trend of the damping factor.

**Figure 5.** Validation of model A (blue, dash-dot-dotted), C.1 (magenta, loosely dashed), C.2 (green, dash-dotted), D.1 (orange, dashed) and D.2 (teal, dotted) by comparison of the step responses to the results in [33]. These are estimates of the second-order characteristics of repeated estimates. The 95% interval of the estimation results is shown in light gray, the 50% interval in gray and the median is illustrated as a black line.

estimation data and the validation data of the PRMS and minimal for the estimation data and the chirp validation data. In addition, an overall NRMSF of at least 80% for both estimation signals and an  $a_x$  NRMSF of 73%/70% is reached by model D.1. Furthermore, with 80%/79% average NRMSF, the fit to the validation data is also good. Although, the  $a_x$  NRMSF for the PRMS validation data is not better than for most other models, the comfort rating is with a RAE of  $-1\%$  very accurate. The nonlinear traction curve of model D.2 is not or only slightly increasing the fit in comparison to model D.1. All in all, it can be stated, that model D.1 and model D.2 are fitting the experiments best. They are the only models, where the NRMSF of each estimation signal is above 70%. Based on our experience, this is a rough threshold for models being suitable for control design. Therefore, the model can be used for all control methods that use a subset of the fitted signals  $y$ . The third most accurate model is C.2, which has a good average fit, but is not fitting the control relevant acceleration well. Model C.1 has only a slightly worse fit, but has linear dynamics (except for the backlash). Model B.1 - B.3 don't have clear advantages in comparison to the basic two inertias model A. Consequently, model A, C.1., C.2, D.1 and D.2 are investigated further and compared to the results in [33]. The complexity of the model and the parameter identification procedure is increasing with the number of parameters. Model A has the least and Model D.2 the most parameters. In [33], the second-order characteristics of the acceleration response to a motor torque step input have been investigated. For the comparative study, the step responses of the model have been simulated for different driving speeds. The second-order characteristics of the responses have been estimated with the same method as in [33]. Figure 5(a) shows, that all models estimate the natural frequency of the system too low. Consequently, the NMFs of all models are negative. However, the RMF is more than 90% for

**Table 3.** Evaluation of candidate models in gear 3

	A		C.1		C.2		D.1		D.2	
	RMF [%]	NMF [%]								
frequency	97	-3	94	-6	94	-7	94	-7	94	-7
damping	57	-38	50	-62	78	30	74	18	74	18

all models (c.f. Table 3). Model A and model C.1 are slip-free and thus independent of the vehicle speed. Their constant damping ratio is intersecting the median in the velocity interval between 10 km/h and 30 km/h below the average damping ratio. Hence, the NMF is below zero again. In contrast, the models C.2, D.1 and D.2 account for the  $\mu - \varepsilon$  relation. Hence, their damping curves have a similar trend as the experiments (c.f. Fig. 5(b)). However, both models underestimate the damping slightly. Consequently, the NMF is not very high, but clearly better than the fit of a model with an averaged constant damping ratio (NMF > 0). The RMF is almost 80% for all models.

To conclude, model D.1 and D.2 are the most accurate models for all experiments. Model D.2 is only slightly more accurate but has more parameters. Therefore model D.1 is recommended for the simulation of drivability-relevant maneuvers.

## 7 Discussion and conclusion

In this paper, the interaction of traction and torsional vibrations has been investigated experimentally. Several physically motivated models have been fitted to two experiments with rich frequency and amplitude content in a wide velocity range. The basic two inertias model is giving good identification results for distinct operating points [33], but cannot cope with the increasing damping ratio of the system with raising velocities. This phenomenon can be simulated by a linear static slip traction curve. Nonlinear curves do not improve the simulation accuracy as critical slip is not reached during the investigated maneuvers. For best results, an additional elasticity can be introduced.

The proposed model D.1 is appropriate for the simulation of all tested experiments, especially for the virtual evaluation of comfort. The only deficiency of the model is that the natural frequency curve has no visible slope for increasing velocities. Hence, the found model is not capturing all phenomena that might be taken into account by further model augmentations. However, a further augmentation of the model by physical principles would heavily increase the identification effort. Additional sensors might be needed at the engine mounts [37] or the clutch [38]. Nevertheless, model D.1 can be used as a nominal model, which is fitting a wide range of excitations in the time-domain as well as

in the frequency domain with NRMSF of 80% on average for all signals and experiments. Another advantage is the simple integration of backlash models. Even though backlash was not deeply treated in this paper, the backlash in the driveline is a challenge for control design (cf. [21]) and is crucial to be considered during controller validation.

To conclude, this research showed the quality of a number of popular models for anti-jerk control design and validation. It was shown that second-order models fit locally, while a nonlinear model is needed in order to simulate a large velocity range. Although this model is able to reach a good fit for all experiments, the model is not able to capture all effects, detected by the experiments.

This shows that the system is quite reliable in its damping properties, but is varying  $\pm 5\%$  from the nominal frequency value. In order to cope with all model uncertainties, robust control methods for uncertain systems could be used. Parameter bounds for the nonlinear system could be a solution (cf. [39]). An unstructured state-space model with defined uncertainties, similar to [6], might be the most promising approach for robust control design.

## References

- [1] K. J. Figel, F. Svaricek, and M. Schultalbers, "Review and experimental evaluation of models for drivability simulation with focus on tire modeling," *Forschung im Ingenieurwesen (acc. for publ.)*, 2019.
- [2] K. Bovee, "Optimal Control of Electrified Powertrains with the Use of Drive Quality Criteria," Ph.D. Thesis, Ohio State University, 2015.
- [3] M. Grotjahn, L. Quernheim, and S. Zemke, "Modelling and identification of car driveline dynamics for anti-jerk controller design," in *International Conference on Mechatronics*. Budapest: IEEE, jul 2006, pp. 131–136.
- [4] S. Eicke, M. Dagen, and T. Ortmaier, "Experimental Investigation of Power Hop in Passenger Cars," *SAE technical papers*, 2015.
- [5] VDI-Richtlinie 2057, "Human exposure to mechanical vibrations: Whole-body vibration," 2015.
- [6] D. H. König, B. Riemann, M. Bohning, R. Syrnik, and S. Rinderknecht, "Robust anti-jerk control for electric vehicles with multi-speed transmission," in *Conference on Decision and Control*. Los Angeles: IEEE, dec 2014, pp. 3298–3303.
- [7] J. Pillas, "Modellbasierte Optimierung dynamischer Fahrmanöver mittels Prüfständen," Ph.D. Thesis, Technische Universität Darmstadt, 2017.
- [8] B. Alt, F. Antritter, F. Svaricek, F. Wobbe, T. Böhme, and D. M. Schultalbers, "Two Degree of Freedom Structure for Reduction of Driveline Oscillations," in *AUTOREG*. Baden-Baden: VDI Berichte 2135, 2011, pp. 361–374.
- [9] U. Angeringer and M. Horn, "Sliding mode drive line control for an electrically driven vehicle," in *International Conference on Control Applications (CCA)*. Denver: IEEE, sep 2011, pp. 521–526.

- [10] K. Togai, K. Choi, and T. Takeuchi, "Vibration suppression strategy with model based command shaping: application to passenger car powertrain," in *SICE Annual Conference*, vol. 2. Osaka: SICE, 2002, pp. 941–943.
- [11] A. Hülsmann, "Methodenentwicklung zur virtuellen Auslegung von Lastwechselphänomenen in Pkw," Ph.D. Thesis, TU München, 2007.
- [12] K. Z. Yeap and S. Müller, "Characterising the interaction of individual-wheel drives with traction by linear parameter-varying model: a method for analysing the role of traction in torsional vibrations in wheel drives and active damping," *Vehicle System Dynamics*, vol. 54, no. 2, pp. 258–280, feb 2016.
- [13] M. Bartram, G. Mavros, and S. Biggs, "A study on the effect of road friction on driveline vibrations," *Journal of Multi-body Dynamics*, vol. 224, no. 4, pp. 321–340, 2010.
- [14] W. Liu, H. He, F. Sun, and H. Wang, "Optimal design of adaptive shaking vibration control for electric vehicles," *Vehicle System Dynamics*, mar 2018.
- [15] M. Rosenberger, M. Kirschneck, T. Koch, and M. Lienkamp, "Hybrid-ABS: Integration der elektrischen Antriebsmotoren in die ABS-Regelung," in *Automobiltechnisches Kolloquium München*, vol. 2, München, 2011, pp. 427–445.
- [16] K. Bovee and G. Rizzoni, "Model-Based Torque Shaping for Smooth Acceleration Response in Hybrid Electric Vehicles," in *International Symposium on Advances in Automotive Control (AAC)*. Norrköping: IFAC, 2016.
- [17] C. F. Caruntu and C. Lazar, "Real-time Networked Predictive Control of a Vehicle Drivetrain with Backlash," in *Nonlinear Model Predictive Control Conference*. Noordwijkerhout: IFAC, 2012, pp. 484–489.
- [18] J. Fan, "Theoretische und experimentelle Untersuchungen zu Längsschwingungen von Pkw (Ruckeln)," Ph.D. Thesis, TU Braunschweig, 1994.
- [19] L. Ljung, *System Identification: Theory for the User*, 2nd ed. Upper Saddle River: John Wiley & Sons, Inc., 1999.
- [20] B. Heißing, M. Ersoy, and S. Gies, *Chassis Handbook*, 1st ed. Wiesbaden: Vieweg+Teubner, 2011.
- [21] A. Lagerberg and B. Egardt, "Estimation of Backlash in Automotive Powertrains — An Experimental Validation," *Advances in Automotive Control*, vol. 37, no. 22, pp. 47–52, apr 2004.
- [22] A. R. Crowther, C. Janello, and R. Singh, "Quantification of clearance-induced impulsive sources in a torsional system," *Journal of Sound and Vibration*, vol. 307, no. 3-5, pp. 428–451, 2007.
- [23] T. Pham, R. Seifried, A. Hock, and C. Scholz, "Nonlinear Flatness-Based Control of Driveline Oscillations for a Powertrain with Backlash Traversing," *Advances in Automotive Control*, vol. 49, no. 11, pp. 749–755, 2016.
- [24] M. Nordin, P. Bodin, and P.-O. Gutman, "New Models and Identification Methods for Backlash and Gear Play," *International Journal of Adaptive Control and Signal Processing*, vol. 11, pp. 49–63, 1997.

- [25] Y. V. Orlov, *Discontinuous Systems*, ser. Communications and Control Engineering. London: Springer London, 2009.
- [26] K. J. Figel, "Backlash models for drivability simulation," Bundeswehr University Munich, Munich, Tech. Rep., 2019.
- [27] T. Pham and L. Bushnell, "Two-degree-of-freedom damping control of driveline oscillations caused by pedal tip-in maneuver," in *American Control Conference (ACC)*. Chicago: IEEE, 2015, pp. 1425–1432.
- [28] C. Canudas-de Wit, P. Tsiotras, E. Velenis, M. Bassett, and G. Gissinger, "Dynamic Friction Models for Road/Tire Longitudinal Interaction," *Vehicle System Dynamics*, vol. 39, no. 3, pp. 189–226, 2003.
- [29] B. Hagerodt, "Untersuchung zu Lastwechselreaktionen frontgetriebener Personenkraftwagen," Ph.D. Thesis, RWTH Aachen, 1998.
- [30] C. L. Clover and J. E. Bernard, "Longitudinal Tire Dynamics," *Vehicle System Dynamics*, vol. 29, no. 4, pp. 231–259, 1998.
- [31] J. W. Biermann and B. Hagerodt, "Investigation of the clonk phenomenon in vehicle transmissions - Measurement, modelling and simulation," *Journal of Multi-body Dynamics*, vol. 213, no. 1, pp. 53–60, 1999.
- [32] G. Götting and R. De Doncker, "Active drive control of electric vehicles using a modal state observer," in *Power Electronics Specialists Conference*, vol. 6. Aachen: IEEE, 2004, pp. 4585–4590.
- [33] K. J. Figel, M. Schultalbers, and F. Svaricek, "Experimental analysis of driveline jerking with focus on the interaction of traction and torsional vibrations," in *International Symposium on Advances in Automotive Control (AAC)*. Orléans: IFAC, 2019.
- [34] C. Bohn and H. Unbehauen, *Identifikation dynamischer Systeme*. Wiesbaden: Springer Fachmedien, 2016.
- [35] M. A. Branch, T. F. Coleman, and Y. Li, "A Subspace, Interior, and Conjugate Gradient Method for Large-Scale Bound-Constrained Minimization Problems," *SIAM Journal on Scientific Computing*, vol. 21, no. 1, pp. 1–23, jan 1999.
- [36] L. Ljung, "System Identification Toolbox™ - User's Guide," Natic, 2018.
- [37] G. Götting, "Dynamische Antriebsregelung von Elektrostraßenfahrzeugen unter Berücksichtigung eines schwingungsfähigen Antriebsstrangs," Ph.D. Thesis, RWTH Aachen, 2004.
- [38] P. Couderc, J. Callenaere, J. Der Hagopian, G. Ferraris, A. Kassai, Y. Borjesson, L. Verdillon, and S. Gaimard, "Vehicle Driveline Dynamic Behaviour: Experimentation and Simulation," *Journal of Sound and Vibration*, vol. 218, no. 1, pp. 133–157, 1998.
- [39] M. Milanese, J. Norton, H. Piet-Lahanier, and É. Walter, Eds., *Bounding Approaches to System Identification*. Boston, MA: Springer US, 1996.

## Aktive Kompensation von Sitzschwingungen in Nutzfahrzeugen

### Auswahl, Integration, Erprobung einer aktiven Sitzhöhenregelung

Dipl.-Ing. **Moritz Plinke**, Dipl.-Ing. **Peter Michael Marienfeld**,

Dipl.-Ing. **Max Werhahn**, Dr.-Ing. **Hans-Jürgen Karkosch**,

ContiTech Vibration Control GmbH, Hannover

#### Zusammenfassung

In zunehmend automatisiert gesteuerten Nutzfahrzeugen verändert sich die Aufgabe des Fahrers vom Fahren zum reinen Überwachen. Damit ändert sich die Wahrnehmung des Sitzkomforts.

Neben klassischen passiven Luftfendersitzen gibt es adaptive und aktiv angesteuerte Sitze, die eine Komfortsteigerung versprechen, jeweils mit systemischen Vor- und Nachteilen. Ziel des vorgestellten Projektes war die Darstellung einer leistungsfähigen Lösung, die das Potential für eine großvolumige Serienanwendung aufzeigt [3].

Dieser Artikel vergleicht das Schwingungsverhalten passiver, adaptiver und aktiver Sitze und stellt Funktionsprinzipien aktiver Sitze dar. Es zeigt sich, dass der Schlüssel zu einer marktgerechten Lösung in der Aktuatorik liegt. Es werden Anforderungen an die Aktuatorik abgeleitet, ein passender Aktuator ausgewählt und in ein marktgängiges Sitzsystem integriert. Anhand von Messergebnissen aus anschließenden Prüfstands- und Fahrzeugversuchen wird die Leistungsfähigkeit des Systems verifiziert.

#### Sitzcharakteristik

Sitzsysteme von Nutzfahrzeugen lassen sich aus mechanischer Sicht in der vertikalen Achse vereinfacht als Einmassenschwinger beschreiben. Die schwingende Masse besteht dabei aus dem beweglichen Teil des Sitzes und dem auf dem Sitz lastenden Anteil des Fahrergewichts. Diese Masse ist über eine Federsteifigkeit und eine Dämpfung an der Kabine gebunden und wird am Anbindungspunkt durch die Kabinenschwingung angeregt. Die Kabinenschwingung wird wiederum über komplexe Übertragungspfade von Motorschwingungen, vor allem aber von Fahrbahnanregungen über die Reifen und das Chassis angeregt (vgl. Bild 1). Die resultierenden Kabinenanregungen sind daher sehr vielfältig und stark von der Fahrsituation ab-

hängig. Besonders anspruchsvolle Schwingungszustände treten bei stoßförmigen Anregungen durch Schwellenüberfahrten und Schlaglöcher sowie bei stochastischer Anregung durch besonders unebene Landstraßen auf.

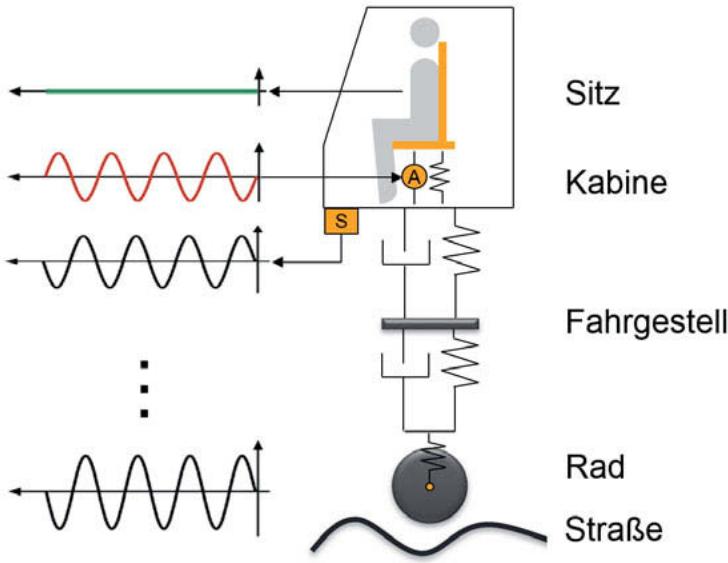


Bild 1: Schematische Darstellung des aktiven Sitzes in einem uniaxialen Ersatzmodell eines Lastkraftwagens

In Bild 2 sind Verstärkungsfunktionen passiver, adaptiver und aktiver Sitze abgebildet. Darunter ist beispielhaft eine spektrale Leistungsdichte (PSD) der Kabinenschwingung bei Fahrt auf einer unebenen Landstraße dargestellt. Die resultierenden sitzseitigen spektralen Leistungsdichten sind der Darstellung hinzugefügt. Bei der Auslegung eines passiven Sitzes besteht grundsätzlich ein Zielkonflikt zwischen einer geringen Resonanzüberhöhung unterhalb des  $\sqrt{2}$ -fachen der Eigenfrequenz, einer hohen Isolation oberhalb dieses Punktes und einer geringen Relativbewegung zwischen Fahrer und Kabine. Die geringe Resonanzüberhöhung und die Isolationswirkung stehen dabei über die Dämpfereinstellung in einem direkten Zielkonflikt (vgl. Bild 2).

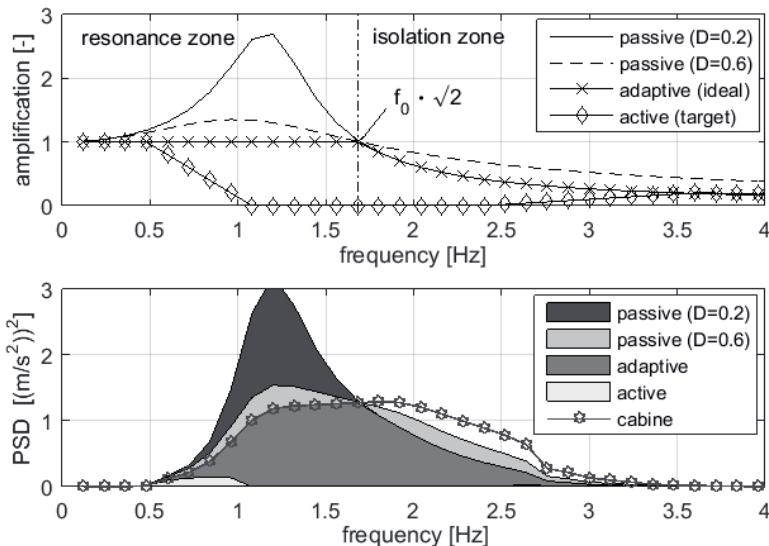


Bild 2: Typische Transferfunktionen passiver, adaptiver und aktiver Sitze (oben) und exemplarische Anregung der Kabine kombiniert mit den entsprechenden Antworten passiver, adaptiver und aktiver Sitze (unten)

Eine generelle Reduktion des Übertragungsverhaltens ist nur durch Absenkung der Resonanzfrequenz des Sitzes möglich. Es besteht jedoch eine Limitierung bzgl. der minimalen Federsteifigkeit des Sitzes. Dies liegt zum einen an der Zunahme der quasistatischen Relativbewegungen des Fahrers zur Kabine, welche das Risiko eines Durchschlagens des Sitzes bei großen Anregungen erhöhen. Zum anderen tritt durch die Bedienung der Pedale und des Lenkrads eine Rückkopplung auf die Sitzposition auf, welche die Bedienbarkeit des Fahrzeuges negativ beeinflusst [1].

Die starke Abhängigkeit der genannten Eigenschaften untereinander führt letztendlich zu der manuellen Verstellbarkeit der Sitzdämpfung, wie sie bei den heutzutage typischerweise eingesetzten Fahrersitzen vorzufinden ist. Je nach Fahrsituation und subjektiver Wahrnehmung des Fahrers bzgl. Komfort und Sicherheit wählt der Fahrer selbst zwischen Isolation und Dämpfung.

Um den Zielkonflikt in der Dämpfereinstellung zu entschärfen, besteht die Möglichkeit einer adaptiven Dämpfung. Dabei verstellt das System auf Grundlage einer oder mehrerer Messgrößen die Dämpfung. Im Optimalfall bleibt ein Aufschwingen des Sitzes durch eine hohe

Dämpfung bei Anregungen im Resonanzbereich aus. Im Falle einer Dominanz höherer Frequenzanteile schaltet das System auf geringe Dämpfung, wodurch die höhere Isolation den Komfort verbessert. Es ergibt sich im theoretischen Optimum ein Übertragungsverhalten, welches sich aus den jeweiligen passiven Kennlinien zusammensetzt (vgl. Bild 2). Somit entschärft sich der Kompromiss zwischen Isolation und Dämpfung, jedoch bleibt die Einschränkung hinsichtlich der minimalen Federsteifigkeit bestehen. Die Schwingungsbelastung auf den Fahrer im Bereich des  $\sqrt{2}$ -fachen der Resonanzfrequenz des Sitzes entspricht daher weitgehend der des passiven Systems.

Erst eine Aktuatorik, die dem Schwingungssystem Energie zuführen kann, ermöglicht eine Reduktion der Schwingungsbelastung auch in diesem Frequenzbereich. Aufgrund des langen Übertragungspfades von der Straße über die Reifen und das Chassis bis zur Kabine bietet sich ein kabinenfester Beschleunigungssensor nah am Einleitungspunkt des Sitzes als Störgrößeneingang an. Das theoretische Ziel ist, die hier aufgenommene Schwingung genau entgegengerichtet über die Aktuatorik wieder einzuleiten, sodass die Anregung vom Fahrer vollständig isoliert wird (vgl. Bild 1). Im quasistatischen Anregungsbereich ist eine Kompensation nicht nötig und nicht erwünscht. Um die Mittelposition des Fahrers zu erhalten und die benötigten Freiwege zur Kompensation störender Anregungen nicht unnötig zu reduzieren, ist eine Hochpasscharakteristik zwingend erforderlich. Im Bereich höherer Frequenzen kann auch die Aktuatorik wiederum über passive Elemente von der Kabine bzw. dem Sitz entkoppelt werden. Dadurch reduziert sich der benötigte Frequenzbereich der aktiven Entkopplung. Ein angestrebtes Verhalten ist in Bild 2 abgebildet.

## Systemkonfiguration

Zunächst stellt sich die Frage der Systemanordnung. Es ist eine parallele, serielle oder inertielle Anordnung des Stellglieds relativ zur passiven Lagerung des Sitzes möglich (vgl. Bild 3). Dabei ist die Anordnung über eine Inertialmasse (c) besonders für kleine Anregungsamplituden in höheren Frequenzbereichen geeignet. Für niedrige Frequenzen ist jedoch eine sehr große Schwungmasse nötig. Bei einer seriellen Anordnung (b) trägt die Aktuatorik dauerhaft die statische Last. Diese Anordnung ist für sehr niederfrequente Anregungen und große Stellwege geeignet, benötigt aber ein große Aktorkraft. In der parallelen Anordnung (a) übernimmt die schon vorhandene Feder die statische Last. Die Aktuatorik bringt nur eine Differenzkraft auf, die das Schwingverhalten beeinflusst, und somit deutlich kleiner als bei einer seriellen Anordnung ausfallen kann. Deshalb fällt die Wahl in diesem Projekt auf die parallele Anordnung.

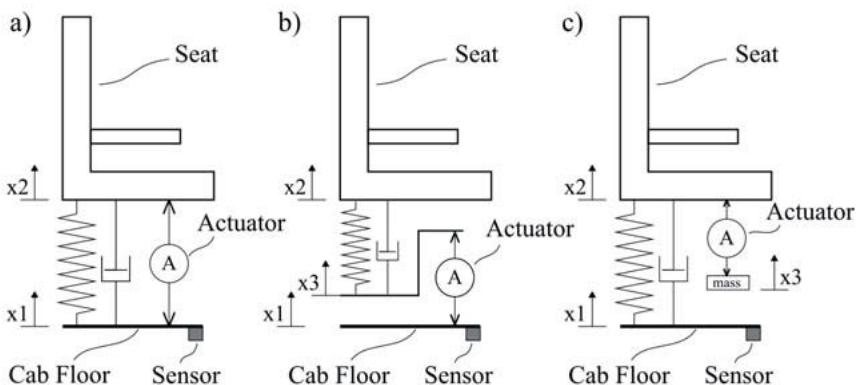


Bild 3: Parallel(a), seriell(b) und inertial(c) angeordnete Aktuatoren

Als Aktuatorik kommen hydraulische, pneumatische und elektrische Antriebe in Frage. Die Anforderungen an die Aktuatorik ergeben sich aus der Systemanordnung. Die parallele Einbindung erfordert Kräfte entsprechend des maximalen Hubs in Kombination mit der Federsteifigkeit des passiven Sitzes zzgl. der eigenen Trägheit. Die benötigte Dynamik entspricht dem Anregungsspektrum der Kabine. Daraus ergibt sich eine Kraftanforderung von ca. 1 kN, maximale Geschwindigkeiten von ca. 0,5 m/s und Beschleunigungen von ca. 5 m/s<sup>2</sup>. Zusätzlich bestehen die Anforderungen einer einfachen und flexiblen Integrierbarkeit, einem geringen Energiebedarf und einer kostengünstigen Verfügbarkeit in Form von industrialisierten Komponenten.

Pneumatische Antriebe besitzen einen begrenzten dynamischen Einsatzbereich und scheiden daher für LKW-Sitze aus. Hydraulische Systeme sind hochdynamisch einsetzbar, weisen allerdings einen hohen Energiebedarf auf und sind von der Verfügbarkeit einer hydraulischen Versorgung abhängig. Die Wahl fällt daher auf einen elektrischen Antrieb. Hier bietet sich ein klassischer bürstenloser DC-Motor mit einer mechanischen Übersetzung der Rotation in eine Translation an. Der Vorteil gegenüber einem direkten Linearantrieb liegt dabei insbesondere in der hohen Leistungsdichte, der Wirtschaftlichkeit und der guten Abstimmbarkeit des Übersetzungsverhältnisses. Dafür kommt ein besonders spielfreier Kugelgewindetrieb zum Einsatz.

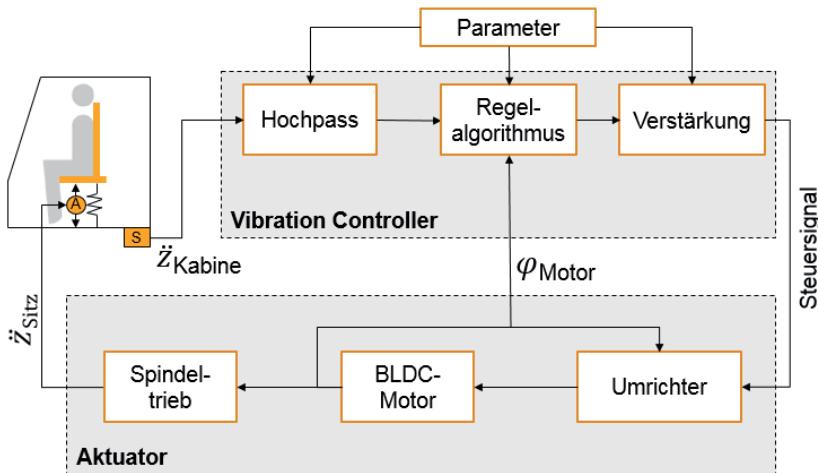


Bild 4: Regel-System

Das realisierte System ist schematisch in Bild 4 dargestellt. Der kabinenseitige Beschleunigungssensor detektiert die Kabinenbewegung und gibt das Signal an den Vibration Controller weiter. Hier findet zunächst eine Hochpassfilterung statt. Anschließend berechnet der Regelalgorithmus die Stellgröße, welche im Nachgang ein Verstärkungsfaktor skaliert. Das resultierende Steuersignal bildet den Eingang für den Aktuator und wird vom Umrichter verarbeitet. Dieser treibt den BLDC-Motor, welcher seine Position über einen entsprechenden Sensor zurückmeldet. Die Positionsinformation wird sowohl an den Umrichter zurückgeführt, als auch dem Regelalgorithmus zur Verfügung gestellt. Dadurch kann die momentane Position des Sitzes im Vibration Controller berücksichtigt werden. Ein Kugelgewindetrieb wandelt die Rotation des Motors in eine Translation und leitet eine passende Kraft zwischen Sitzfläche und Kabine ein, die zur Isolation der Sitzfläche von der Kabinenbewegung führt.

### Laborerprobung

Eine Laborerprobung validiert den gewählten Ansatz auf einem uniaxialen Prüfstand. Dabei dient als Referenzsignal die Vertikalkomponente der Kabinenbewegung auf einer schlechten Landstraße. Bei Einstellung der Ansteuerung auf bestmögliche Kompensation der Bewegung der Sitzfläche reduzierte sich die resultierende PSD um ca. 90 % (vgl. Bild 5).

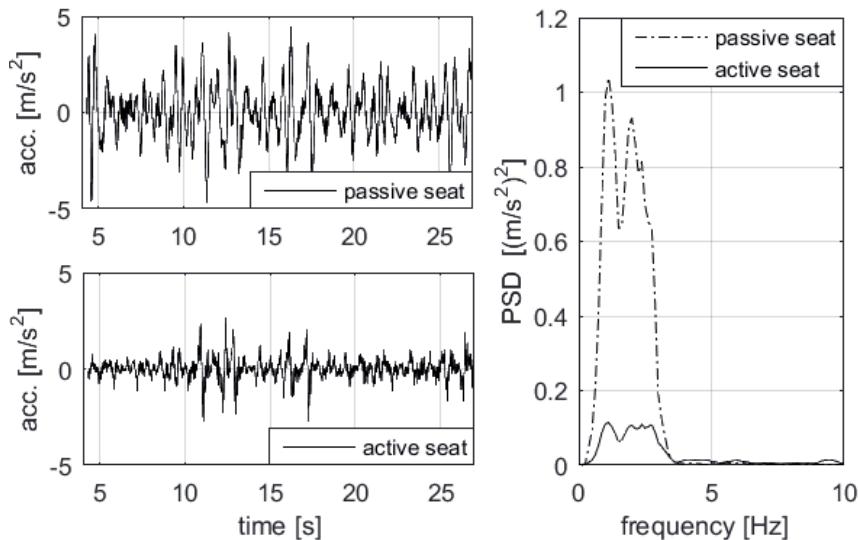


Bild 5: Zeitsignal der Beschleunigung der Sitzoberfläche bei einem passiven (oben) und aktiven Sitz (unten) sowie das jeweilige Energiespektrum (rechts), jeweils auf dem Prüfstand gemessen

Das System erfüllt somit die mechanischen Voraussetzungen einer nahezu vollständigen Kompensation der Vertikalbeschleunigungen im Fahrzeug.

### Fahrzeugintegration und -erprobung

Ausgehend vom Laboraufbau wurde ein kompakterer Aufbau zur Integration in den Sitzkasten entwickelt. Bild 6 zeigt die parallele Anordnung von Motor und Spindeltrieb, bei der ein Zahnrämen das Motormoment auf die Spindelmutter überträgt. Die Spindel ist rotationssteif mit dem oberen Teil des Sitzes verbunden und bewegt die Sitzfläche. Der benötigte Bauraum entstand durch die Entfernung des passiven Dämpferelements.

Zur Erprobung auf einem Testgelände wurde der Sitz in einer Schwerlast-Zugmaschine installiert. Im Fokus der Untersuchung standen dabei Schlechtwegstecken, Schlaglöcher und Sisusanregungen. Beispielhaft sind in Bild 7 die Messergebnisse einer Testfahrt über eine Reihe von Einzelhindernissen dargestellt.

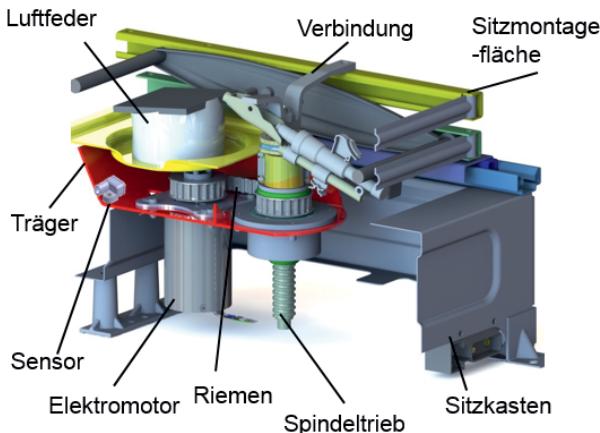


Bild 6: Integration des Aktuators im Sitzkasten eines Seriensitzes

Zum Vergleich wurden die Beschleunigungen sowohl kabinenseitig als auch sitzseitig erfasst. Gegenübergestellt sind die Resultate des passiven und des aktiven Sitzes. Die sitzseitige Beschleunigung wurde dabei am Sitzrahmen unterhalb des Sitzkissens gemessen. Dadurch ist der direkte Einfluss der Aktuatorik zu erkennen. Es war eine Reduktion der sitzseitigen Beschleunigung von ca. 50% im Frequenzbereich zwischen 1 Hz und 3,5 Hz erreichbar. Über 4 Hz zeigte die Aktuatorik keine Wirksamkeit. Hier treten lediglich sehr kleine Anregungsamplituden auf, die durch das Sitzkissen zusätzlich isoliert werden.

Das Isolationsniveau kann und sollte dabei nicht auf dem theoretisch möglichen des Prüfstandes gehalten werden, da im realen Umfeld weitere Optimierungsziele zu berücksichtigen sind. So wurde durch eine sehr starke Isolation eine Art Schwebeffekt erzeugt, der nur dann als besonders angenehm empfunden wurde, wenn sich der Fahrer währenddessen physisch von Lenkrad und Pedalen löste und die Relativbewegung zur Kabine weniger wahrgenommen wurde. Da dies nicht über längere Zeit möglich ist, ist ein Kompromiss aus hoher Kompensation bei Einzelanregungen und sukzessiver Reduktion bei andauernder Anregung nötig. Ein Übersprechen von Querbeschleunigungen z.B. durch Wank- und Nickbewegungen macht weiterhin eine stärkere Hochpassfilterung nötig, um ein Driften der Mittelposition zu unterbinden. Im Randbereich des Sitzfreiweges war zudem eine elektronische Wegbegrenzung nötig. Die Gewährleistung einer besonders weichen Progression schränkt den Bereich maximaler Kompensation zusätzlich ein.

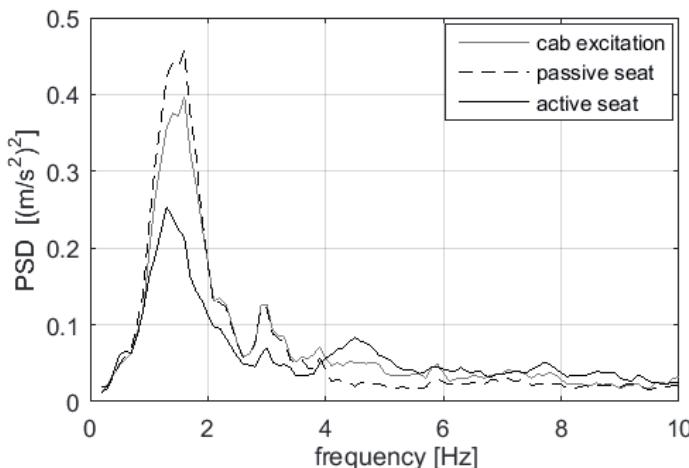


Bild 7: Energiespektren der Kabinen- und Sitzflächenbeschleunigung im Vergleich, ermittelt aus Testfahrten über wellige Fahrbahn und Schlaglöcher

Die zusätzlichen Zielsetzungen konkurrieren mit dem Kompensationsniveau und werden je nach Fahrer unterschiedlich gewichtet. Zudem kann je nach Fahrsituation eine andere Konfiguration ein Optimum darstellen. Eine manuelle Adaption der Regelungsparameter auf das subjektive Empfinden und die Fahrsituation hat sich daher als sinnvoll herausgestellt.

### Zusammenfassung und Ausblick

Eine aus industrialisierten Komponenten aufgebaute Aktuatorik erfüllt die Anforderungen, die ein aktiver LKW-Sitz stellt. Die Komponenten lassen sich in einen entsprechenden konventionellen Luftfegersitz integrieren. Es fand eine Anpassung der Regelung an den realen Fahrbetrieb statt. Die Versuchsergebnisse zeigen, dass der Regelungsansatz mit einem uniaxialen Beschleunigungssensor und einem Positionssensor geeignet ist, eine deutliche Reduktion der Schwingungsbelaustung des Fahrers im Fahrzeug zu erreichen. Somit zeigt der gewählte Ansatz das Potential, die Arbeitsbedingungen von Berufskraftfahrern zu verbessern. Im Verlauf hat sich herausgestellt, dass die nahezu vollständige Schwingungsentkopplung des Fahrers im niederfrequenten Bereich zwar möglich ist, aber hinsichtlich der aktuellen Aufgaben des Fahrers nicht als vorteilhaft empfunden wurde.

Im Kombination mit autonomen Fahrzeugen, bei denen der Fahrer nicht primär fährt, sondern hauptsächlich überwacht, kann die Leistungsfähigkeit des aktiven Sitzes voll zum Tragen kommen: Der Fahrer genießt losgelöst von der Relativbewegung der Kabine einen Komfort, der zum Wohlempfinden und der Erhaltung der Gesundheit beitragen kann.

Zur weiteren Optimierung könnte eine mehraxiale Sensorik dazu beitragen, die zu kompensierenden Vertikalschwingungen von übersprechenden Querbeschleunigungen zu trennen. Zudem ist es empfehlenswert, dem Fahrer eine Anpassbarkeit des Reglers auf dessen subjektives Empfinden zu bieten.

- [1] Hauck, M: Geregelte Dämpfung für Traktor-Fahrersitze, Berlin, 2001, 10 -16
- [2] Der Mensch im Transport- und Logistikmarkt, ZF Zukunftsstudie Fernfahrer 2.0, Friedrichshafen Heilbronn Stuttgart 2014
- [3] Werhahn, M., Karkusch, H.-J., Marienfeld, P.M.: Active Vibration Control in Truck Seats, ACTUATOR18, International Conference and Exhibition on New Actuators and Drive Systems, Bremen, 25.-27. Juni 2018

## Objectification Methods for Ride Comfort

### Comparison of Conventional Methods and Proposal of a new Method for Automated Driving Conditions

M.Sc. **E. Enders**, B.Sc. **F. Fent**, Prof. Dr.-Ing. **M. Lienkamp**,  
Technical University wof Munich, Munich;  
M.Sc. **G. Burkhard**, Bayerische Motoren Werke AG, Munich;  
Prof. Dr.-Ing. **D. Schramm**, University of Duisburg-Essen, Duisburg

#### Zusammenfassung

Für eine effektive Fahrwerksentwicklung werden objektive Kennwerte benötigt, welche die Leistungsfähigkeit passiver und aktiver Systeme hinsichtlich des Fahrkomforts charakterisieren. In dieser Arbeit werden verschiedene Objektivierungsverfahren aus der Literatur verglichen, sowie ein neues Vorgehen für automatisierte und autonome Fahrsituationen vorgestellt. Zur Bewertung der verschiedenen Verfahren wurden zwei Probandenstudien durchgeführt. In der ersten Studie wurden die bestehenden Methoden verglichen. Sechzehn Testpersonen sind hierfür in einem BMW 650i (F06) auf einer Landstraße gefahren und mussten dabei verschiedene Dämpfereinstellungen auf einem bestimmten Testabschnitt bewerten. Die während der Fahrt aufgezeichneten Beschleunigungsdaten werden anhand der ISO-2631:1997 [29] (gleich der VDI-2057:2017 [69]), der BS 6841:1987 [7] sowie den Methoden nach Rericha [60], Cucuz [13], Klingner [32] und Hennecke [28] ausgewertet und mit den Subjektivbeurteilungen verglichen. Da Subjektivbewertungsdaten ein ordinales Skaleniveau zu Grunde liegt, wird die Korrelation durch dafür geeignete Verfahren wie den Rangkorrelationskoeffizienten Kendalls-Tau und allgemeine explorative Statistik untersucht. An der zweiten Studie haben insgesamt vierzig Probanden teilgenommen. Sie mussten dabei in einem BMW 135i (F20) ebenfalls auf einer Landstraße fahren, jedoch waren sie einmal der aufmerksame Fahrer, das andere Mal ein abgelenkter Beifahrer. Im abgelenkten Fall haben die Probanden auf einem Tablet einen Fragebogen ausgefüllt. Während der Fahrt wurden dann vier verschiedene Straßenabschnitte von den aufmerksamen und abgelenkten Probanden bewertet. Auftretende Beschleunigungen an den Insassen wurden mit einer Körpermesstechnik [9] und einem Sitzkissen nach ISO-10326 [30] aufgezeichnet. Diese Daten werden ebenfalls mit den Subjektivbewertungen verglichen. Die Ergebnisse der ersten Studie zeigen, dass die standardisierten Verfahren (ISO-2631 [29], VDI-2057 [69] und BS 6841 [7]) die höchste Übereinstimmung aufweisen. Die Methode nach Klingner [32] war die beste nicht standardisierte Methode. Die Ergebnisse der zweiten Studie zeigen einen signifikanten Un-

terschied in der subjektiven Bewertung zwischen aufmerksamen und unaufmerksamen Probanden. Es zeigt sich zudem, dass unaufmerksame Probanden höhere RMS Beschleunigungswerte am Kopf erfahren, was man ebenfalls im Fahrzeug zu Kopf Übertragungsverhalten sehen kann.

## Abstract

For efficient suspension development, objective performance indicators are needed which quantify the system with regard to ride comfort. This paper aims to investigate the capabilities of objectification methods from literature and presents a new method for automated and autonomous driving situations. Two studies were conducted in order to investigate objectification methods for ride comfort. In the first study, different objectification methods from literature were tested and compared. Sixteen subjects drove on a country road with a BMW 650i (F06). The subjects had to rate different damper settings which were tested at the same road section. The sensor data was evaluated according to ISO-2631:1997 [29] (equal to VDI-2057:2017 [69]), BS 6841:1987 [7], as well as according to the methods of Rericha [60], Cucuz [13], Klingner [32] and Hennecke [28]. As subjective ratings imply ordinally scaled data sets, the correlation between the objective values and the subjective ratings is tested with the rank-correlation coefficient Kendalls-Tau and exploratory statistical methods. In the second study, forty participants drove and were driven around country roads in a BMW 135i (F20). The inattentive occupants had to perform an activity on a tablet which distracted them from the current driving situation. The subjects had to rate the ride comfort on four different road sections. Measurements have been conducted with a self-developed body measurement system [9] and a seat pad sensor according to ISO-10326 [30]. The measurements and subjective ratings were correlated and statistically analyzed. The results of the first study show that the ISO-2631 [29], VDI-2057 [69] and BS6841:1987 [7] perform best under the given test conditions. The method of Klingner [32] shows the best results of the non-standardized methods. The results of the second study show a significant difference in comfort perception between attentive and inattentive occupants. It can also be seen that inattentive occupants show higher values of RMS accelerations measured at the head, which is also visible in the vehicle to head transmissibility.

## Introduction

The first sketch of an autonomous vehicle dates back to 1500 and was drawn by Leonardo da Vinci [55]. Roughly 500 years later, the automotive industry started to guide their development towards partly automated and autonomous vehicles, and with the introduction of the Tesla Auto Pilot in 2014, other manufacturers were forced to offer more advanced driver assistant systems [51]. In this process, they took the initiative and stated goals regarding the introduction of the first cars which have the possibility to drive fully autonomous in certain scenarios. A lot of research towards autonomous driving is focusing on Human Machine Interfaces, the automated driving task and the traffic infrastructure, but also the customer requirements on autonomous cars are investigated. It is expected that the importance of ride comfort will increase as good ride quality is necessary to engage in secondary tasks without distraction.

## Motivation and Goals

Objectification methods for comfort help to quantify ride comfort and are investigated in this research. A variety of methods are known from literature, but the performance of these methods and how they compare has not been studied in detail. No information on the influence of secondary tasks and the state of attention on ride comfort perception in passenger cars could be found. As a result, this research was performed to address this lack of knowledge. The goal is to give a comprehensive overview on established objectification methods, investigate the influence of attention on comfort perception, and test if there is a correlation between comfort perception and head motion.

## Whole Body Vibrations

Humans perceive vibrations by combining visual, vestibular, somatic and auditory signals [42]. Different studies have been conducted to investigate whole body vibration (WBV) and it is important to distinguish between comfort, discomfort and vibration discomfort. Vibration discomfort is only a subset of general discomfort, which also includes other forms of discomfort, e.g. thermal or acoustic discomfort [26]. Comfort and discomfort are two independent variables, where discomfort is associated with bio-mechanical factors and comfort is associated with relaxation and well-being, so that the absence of discomfort does not necessarily imply comfort [70]. Criteria for comfort can be visualized by the comfort pyramid, which consist of smell, light, vibration, noise, climate and anthropometry, where smell is at the base and anthropometry at the top [36]. If basic needs are fulfilled, the next higher needs become

relevant, which is in accordance with basic principles of human perception and is based on the theory of human motivation and necessities [44, 8]. In order to objectify comfort, it is therefore necessary to understand the human perception and map all sorts of sensory inputs of the human to subjective ratings. An example for a human perception model can be found in [41]. The mapping of perceived vibrations to subjective ratings is strictly speaking only an objectification of vibration discomfort, as depicted in ISO-2631 [29], BS 6841 [7] and VDI-2057 [69]. In the automotive context this fact is often overlooked or ignored. Standards such as ISO-2631 [29] rely on gathered knowledge in WBV, but research suggests that some factors are still not totally understood. Frequency weightings defined in ISO-2631 [29] were found to underestimate the sensitivity of subjects to horizontal vibration under multi-axial vibration [43]. The influence of posture on perceived discomfort is also under investigation [15, 16]. In a recent study it could be shown that gender has an effect on vibration power absorption for subjects of comparable anthropometric dimensions and that the absorption is correlated to the body mass, body fat and lean body mass, but no definite trends were found for stature related parameters such as sitting height [17]. Modelling the bio-dynamic response characteristics is also tried with different model types. One approach is to use lumped parameter models and identify them with the help of seat-to-head transmissibility and driving-point mechanical impedance [5]. Another approach is the use of more complex multibody models or non-physical black box models like neural networks [24, 25]. Human perception thresholds as well as noticeable differences in vibration magnitude have also been studied [2, 45]. The seat backrest is another factor that has an influence on perceived discomfort under WBV [53, 52]. The understanding of human body biodynamics can be regarded as a baseline for the development of virtual human models, vibration isolation systems and definition of new objectification methods for human vibration discomfort [57].

### **Objectification of Ride Comfort in Passenger Cars**

A common procedure for the objectification of comfort in cars is to use standards like the ISO-2631 [29], BS 6841 [7] and VDI-2057 [69], as they allow consistent and reproducible assessment of discomfort in most situations [6]. Griffin [27] states that there will always be imperfect predictions of vibration discomfort when other factors such as seating discomfort or noise are influencing the judgments, but also identifies limitations of the standards regarding the influence of vibration magnitude, frequency, direction, location and duration. Early efforts to objectify ride comfort in passenger cars have been undertaken by Lee and Simic [38, 63]. An investigation of Smith [64] showed a strong correlation between RMS acceleration values at the floor board and passenger seat interface to subjective ride comfort ratings. Recent

attempts to improve objectification of ride comfort are based on the ISO-2631 [29]. They augment the method by taking into account other measurements or by applying different weightings. Rericha [60] claims to improve correlation by taking into account steering wheel vibration, Cucuz [13] considers pulses due to single obstacles in the objective measurements and Klingner [32] takes into account additional rotational and translational degrees of freedom at the backrest, the feet and the seat measurement point. The model of Klingner [32] was specifically developed for objectification of stochastic road disturbances and engine shake [46]. Hennecke [28] developed a method based on the theory that stochastic vibrations are rated more severe than harmonic vibrations, only considering heave and pitch motion. Other methods focus on objectification of individual vibration phenomena, such as seat riding, copying, wheel hop and engine shake [47]. These individual criteria can be objectified by using a modal analytic approach [54, 35, 34]. It is also possible to use continuous weightings based on the intensity ratio of different measurement signals [31]. Prediction of long distance comfort in passenger cars was investigated in [59]. Other sources show ride-meters to benchmark different cars on certain criteria [66, 37, 58]. The definition of perception dimensions and the correlation of their ratings to objective measurements can be found in [40, 39]. Transfer functions can be used to identify and rate vehicle specific characteristics as well as to estimate seat pad vibration [19, 1]. The evaluation of vibration comfort in a simulator is shown in [3, 50]. A physical system for repeatable measurements of dynamic seating comfort is presented in [49]. Machine learning methods such as artificial neural networks and random forests have also been used to objectify ride comfort [65, 33].

### Ride Comfort for Automated and Autonomous Driving

In an autonomous vehicle, it is expected that the occupants will use the spare time to follow different activities during their journey [18]. The perception of the ride changes because the occupant is out of the loop, which results in larger body movements of the distracted occupants, for example due to lateral acceleration [10]. There are indications that longitudinal and lateral dynamics have a significant impact on the comfort of the occupants and vertical dynamics only have a secondary effect [48]. The trajectory of the automated vehicle has a strong influence on ride comfort and sense of security, as a consequence upper limits are set for distances and accelerations related to the trajectory [22, 23]. It is expected that one of the first applications of automated driving will be traveling on a highway with constant speed and low lateral accelerations [67].

In this scenario, an occupant will only perceive low longitudinal and lateral accelerations [20] and the vertical dynamics heave, pitch and roll will remain as major factors for ride comfort [27]. It is an open question for research if ride comfort under automated or autonomous driving conditions can still be determined with the methods developed for conventional driving.

### **Method: Comparison of established Objectification Methods**

The aim of Study I was to benchmark existing objectification methods based on, or comparable to the ISO-2631 [29]. The following methods were compared:

- ISO-2631:1997 [29] (equal to VDI-2057:2017 [69])
- BS 6841:1987 [7]
- RERICHA [60]
- CUCUZ [13]
- KLINGNER [32]
- HENNEKE [28]

Accelerations were measured at the seat, the backrest and the feet contact points. Cucuz [13], Klingner [32] and Rericha [60] additionally take into account accelerations, measured at the steering wheel. The method of Rericha [60] also uses the angular acceleration of the steering wheel. A falsification approach was used to test the work hypotheses, which is recommended if it is not possible to control all disturbances and the variable of interest (e.g. discomfort) is not directly measurable [62]. Possible disturbances for the assessment could be subject characteristics, such as age, weight, experience, but also the expectation regarding the test vehicle, the accustomed ride comfort, or environmental influences, such as light, noise, smell or the road condition. The study was a Within-Subject-Design with randomization and consists out of an objective and a subjective part. The objective part describes the measurement and processing of physical variables such as translational accelerations and rotational velocities, which are used to calculate a quantifiable discomfort value.

Tab. 1: Sample Composition of Study I – 16 subjects,  
19% female

	age in yrs	size in cm	weight in kg
<b>min</b>	25	162	47
<b>max</b>	45	199	99
<b>mean</b>	29.1	182.6	77.7
<b>std</b>	4.5	10.2	14.7

The subjective part describes the acquisition and statistical evaluation of discomfort ratings by the subjects. Table 1 shows statistical data of the sample composition. The subjects had to drive on a country road section with a length of 1.5 km (Figure 1). Each had to drive four times with three different damper modes, soft, hard and controlled. The controlled mode corresponds to the production-line comfort setting of the semi-active suspension. A BMW 650i Grand Coupe (F06) was used as a test vehicle. Each subject had to drive the road in both directions, two times from north to south, two times from south to north. The order of the different settings was randomized and the last drive was always a repetition of the first one using the same damper mode. The car had to be driven at a constant speed of 60 kph, which was enforced by using the speed limiter function. For a specific damper mode, the subject had to rate the perceived discomfort on a six-level Likert scale with the anchor points "not uncomfortable" (1) and "extremely uncomfortable" (6), which are based on the wording in ISO-2631 [29]. The perceived discomfort was questioned for the different measurement points as well as a total impression.

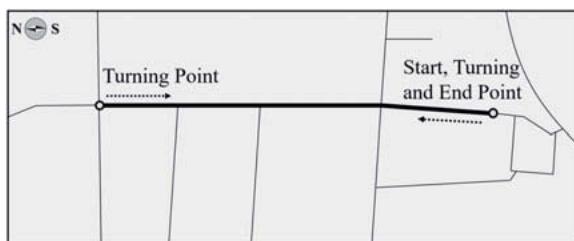


Fig. 1: Study I test section on Goldacher Street between Goldach and Zengermoos near Garching

During each drive, accelerations and angular velocities were recorded at the foot well, the steering wheel, the seat pad and the backrest. For measurement at the seat pad a capacitive

six degree of freedom sensor by Dytran<sup>©</sup> (7556-A1) was used which records triaxial accelerations and angular velocities. For the other positions, triaxial piezoelectric accelerometers by PCB Piezotronics<sup>©</sup> (356-A16) were used. The angular rates at the seat pad were numerically differentiated to obtain the angular accelerations as input for the different methods. To apply the method of Rericha [60] it was additionally necessary to differentiate the steering wheel angle two times to get the angular acceleration of the steering wheel. The steering wheel angle was logged via the CAN-Bus of the test vehicle. The correlation between the estimated discomfort ratings and the rated discomfort is calculated with the rank-correlation coefficient Kendalls-Tau (eq. 1), which is suitable for ordinally scaled data sets [11].

$$\tau_b = \frac{P - I}{\sqrt{\frac{n(n-1)}{2} - T} \left( \frac{n(n-1)}{2} - U \right)} \quad (1)$$

$$\text{with } T = \frac{\sum_{i=1}^b t_i(t_i - 1)}{2} \quad \text{and} \quad U = \frac{\sum_{i=1}^c u_i(u_i - 1)}{2}$$

The objective values are analysed by their arithmetic mean, maximum, minimum and standard deviation. By using the standard deviation and the arithmetic mean, the variation coefficient can be calculated (eq. 2), which is a measure for the relative size of the standard deviation compared to the mean value. It can be used to compare the spread of data sets, where each data set consists of a different physical or empirical quantity.

$$c_{var} = \frac{\sigma}{\mu} \quad (2)$$

$$\text{with } \mu = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{and} \quad \sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}$$

Another interesting indicator is the ratio of the standard deviation to the difference between the mean values of two different settings (eq. 3). This can be seen as the signal to noise ratio of the objective value. The closer this ratio is to zero, the clearer is the difference between two settings in the objective value of a method.

$$\tau_{ij} = \frac{\max(\sigma_i, \sigma_j)}{\mu_j - \mu_i} \quad \text{for} \quad \mu_i \neq \mu_j \quad (3)$$

### Method: Objectification with Body-Based Measurements

The aim of Study II was to evaluate the influence of the attention level on the perceived ride comfort and if it is possible to use body based measurements for objectification of ride comfort. The body movements were measured with a body measurement system which is described in [9]. Comparable systems can be found in [56, 14]. The body measurement system measures accelerations and angular rates at the occupants' body and on the car. Capacitive six degree of freedom sensors by Dytran<sup>®</sup> (7556A1) are used for this. To measure the seat pad acceleration for evaluation according to the ISO-2631 [29], a compliant seat cushion according to ISO-10326-1 [30] was used which contains a triaxial piezo-electric accelerometer by PCB Piezotronics<sup>®</sup> (356A16). The study was conducted in real traffic with forty subjects. Test vehicle was a BMW M135i (F20) with a sportive chassis tuning. It was chosen to represent a worst case scenario for an automated driving car. A lap of approximately 13 km of single lane road was used as test track and it included four different kinds of road excitation. Figure 2 shows the schematic overview of the lap and its sections.

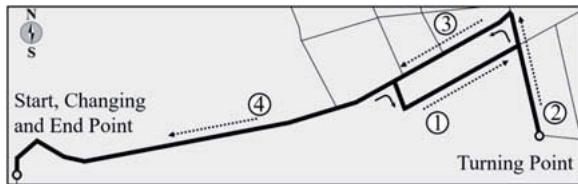


Fig. 2: Schematic overview of the lap and its sections in Study II, located north of the BMW test facility in Aschheim

Each measurement was conducted on a straight track at a constant speed of 70 km/h for each section. Section one of the track is an undulating road that results in low-frequency heave and pitch motion of the vehicle body (Figure 3). The second section has damaged pavement layers at the road-side that result in roll motion. Section three is a recently asphalted road with minimal excitation. The last section four has damaged pavement layers with many provisional repairs that lead to strong heave, pitch and roll motion. While driving through a test section the drivers', the co-drivers' and the car's movements were constantly captured by the body measurement system.

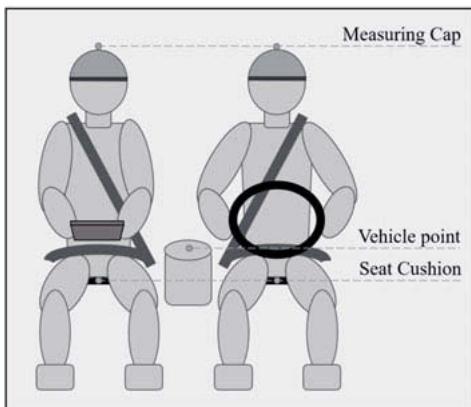


Fig. 3: Positioning of the sensors in Study II

The subjects participated in pairs of two as attentive driver and inattentive co-driver, each representing one state of attention. The attentive driver used the speed limit function for the test sections to ensure a constant vehicle speed. The co-driver performed tasks on an 8-inch tablet. He was instructed to complete a survey about personal details like age, weight and driving experience. Both tasks and the measurements were monitored by the investigator sitting in the backseat in order to record any irregularities. An introduction lap was driven to demonstrate the route for both subjects. Afterwards, the first measurement lap was conducted followed by a driver change and the second measurement lap. For the subjective evaluation, the occupants were interviewed during and after the ride. To determine the subjectively experienced discomfort of an excitation, a 7-step (odd) unipolar Likert scale with verbal marks from one to seven was used. According to Schwarz et al. [61] the reliability of a study increases with completely verbalized scales. Anchor points for the grading scale were "very pleasant" to "very unpleasant". After each section, the subjects had to rate the vibration discomfort for the past road section. An interview concerning the overall lap was conducted during the driver change after the first lap and at the end of the study. Table 2 shows the sample composition of Study II. All subjects were employees of the BMW Group with no deeper experience in autonomous driving or driving comfort. The study involved four female and thirty-six male subjects. The root mean square (RMS) acceleration values of the body based sensors have been chosen as objective quantities in Study II.

Tab. 2: Sample composition of Study II – 40 subjects,  
10% female

	age in yrs	size in cm	weight in kg
<b>min</b>	23	153	55
<b>max</b>	57	202	110
<b>mean</b>	38.2	182.6	80.8
<b>std</b>	9.6	9.4	12.7

For each track and each measurement direction (x, y and z), as well as in both states of attention, the RMS value is calculated for each attentive subject as  $RMS^{(at)}$  and each inattentive subject as  $RMS^{(in)}$ . Based on this, the effective value ( $RMS_i$ ) is calculated (eq. 4) as the average of the RMS values for the attentive and inattentive subject of a test couple. For each section, these values are averaged and represent the mean acceleration value the subjects experienced independent of the state of attention on a test section ( $\overline{RMS}^{(E)}$ ).

$$\overline{RMS}^{(E)} = \frac{1}{n} \sum_{i=1}^n RMS_i \quad \text{with} \quad RMS_i = \frac{RMS^{(at)} + RMS^{(in)}}{2} \quad (4)$$

As an indicator for the difference between an attentive and an inattentive occupant, the percentage difference between the attentive and inattentive state  $\overline{RMS}^{(D)}$  is used. It is calculated as the difference in RMS acceleration between the attentive and the inattentive subject of a couple ( $\Delta RMS_i$ ), divided by the associated mean value  $RMS_i$ . This means that a positive value represents the increased RMS acceleration for an inattentive occupant in percent. This is averaged for the different sections as  $\overline{RMS}^{(D)}$  (eq. 5), so a value of zero means that there was no difference between attentive and inattentive at this section. Before discussing and analysing the results it should be noted, that neither in this study, nor in Study I any of the test subject showed symptoms of motion sickness.

$$\overline{RMS}^{(D)} = \frac{1}{n} \sum_{i=1}^n \frac{\Delta RMS_i}{RMS_i} \quad \text{with} \quad \Delta RMS_i = RMS^{(in)} - RMS^{(at)} \quad (5)$$

## Results: Established Methods

The ISO-2631 [29], BS 6841 [7] and the methods of Klingner [32] and Hennecke [28] show distinct levels in their objective values (Figure 4a, b, e, f). Cucuz [13] and Rericha [60] (Figure 4c, d) fail to achieve this and cannot distinguish between different settings.

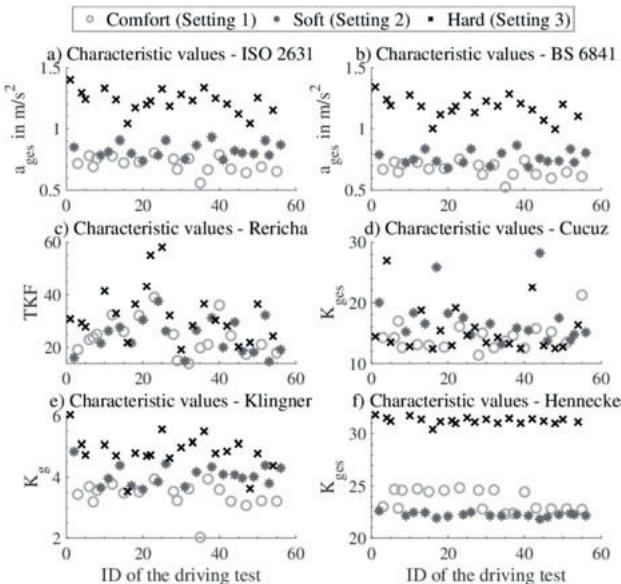


Fig. 4: Objective values for the different methods in Study I [21]

ISO-2631 [29], BS 6841 [7] and the method of Klingner [32] are also showing the expected sequence of the settings, which is "hard" as the worst setting and "controlled" slightly better than "soft" (Figure 4a, b, e). The method of Hennecke [28] rates the setting "soft" better than the setting "controlled" but has the lowest variance in the comfort values for each setting (Figure 4f). Reasons for the larger dispersion in the objective values could be the consideration of impulse content for Cucuz [13] and steering wheel angular acceleration for Rericha [60] (Figure 4c,f). Table 3 shows the mean, the minimum, the maximum, the standard deviation and the variation coefficient of the objective values for each method. The ISO-2631 [29], the BS 6841 [7] and the methods of Hennecke [28] and Klingner [32] show the lowest varia-

tion coefficients (eq. 2). The coefficient is low for a uniform objective value representing a certain setting. A value of 0.09 for the ISO-2631 [29] means that the standard deviation of all objective values for this setting is only 9% of the mean value.

Tab. 3: Mean, maximum, minimum, standard deviation and variation coefficient of the objective values for the different methods

	comfort					soft					hard				
	$\mu$	max	min	$\sigma$	$c_{var}$	$\mu$	max	min	$\sigma$	$c_{var}$	$\mu$	max	min	$\sigma$	$c_{var}$
<b>ISO-2631 [29]</b>	0.71	0.81	0.56	0.06	0.09	0.83	0.93	0.74	0.06	0.07	1.23	1.40	1.04	0.09	0.07
<b>BS 6841 [7]</b>	0.66	0.75	0.53	0.06	0.09	0.76	0.87	0.68	0.06	0.08	1.18	1.34	1.00	0.09	0.07
<b>Rericha [60]</b>	23.12	39.06	14.00	6.85	0.30	24.86	37.53	14.73	6.79	0.27	32.40	58.12	19.24	10.06	0.31
<b>Cucuz [13]</b>	14.75	21.24	11.36	2.41	0.16	18.58	35.34	13.18	5.79	0.31	32.40	26.98	12.40	3.65	0.24
<b>Klingner [32]</b>	3.38	3.94	2.02	0.43	0.13	4.07	4.85	3.60	0.34	0.08	15.35	6.04	3.53	0.54	0.11
<b>Hennecke [28]</b>	23.56	24.84	22.32	0.97	0.04	22.25	22.85	21.82	0.24	0.01	4.83	31.83	30.41	0.30	0.01

The standard deviation in relation to the difference of the mean values between two settings (eq. 3) gives the ratios presented in Table 4. The two standards and the methods of Hennecke [28] and Klingner [32] show the lowest ratios, where a low ratio stands for a clear separation of two settings in the objective value. A negative value like  $r_{12}$  for Hennecke [28] or  $r_{23}$  for Cucuz [13] means that the objective value is opposing the expected order, e.g. the objective values of Hennecke [28] indicate that the soft setting has lower discomfort than the comfort setting.

Tab. 4: Ration between standard deviation and the difference of the mean values for the different settings comfort (1), soft (2) and hard (3)

	$r_{12}$	$r_{13}$	$r_{23}$
<b>ISO-2631 [29]</b>	0.54	0.22	0.17
<b>BS 6841 [7]</b>	0.59	0.21	0.17
<b>Rericha [60]</b>	3.99	1.33	1.08
<b>Cucuz [13]</b>	1.51	-1.80	6.00
<b>Klingner [32]</b>	0.64	0.71	0.38
<b>Hennecke [28]</b>	-0.74	0.03	0.13

The subjective ratings based on the questionnaire can be seen in Figure 5. The boxplots show the total discomfort ratings for the different damper settings, which show the median, the 25%--, the 75%-quartile and a maximum whisker length of 1.5 times the interquartile range. It can be seen that there is an outlier in the rating of the comfort damper setting. The interquartile range is the smallest for the comfort setting, which indicates that it is rated more consistent compared to the two other settings. The median values show that the comfort setting is rated best with a value of 2, followed by the soft setting with a value of 2.5. The hard setting was rated worst with a median of 4. Note that the median of the comfort setting is equal to the 75% quartile, due to the fact that a rating of 2 was chosen very often by the subjects.

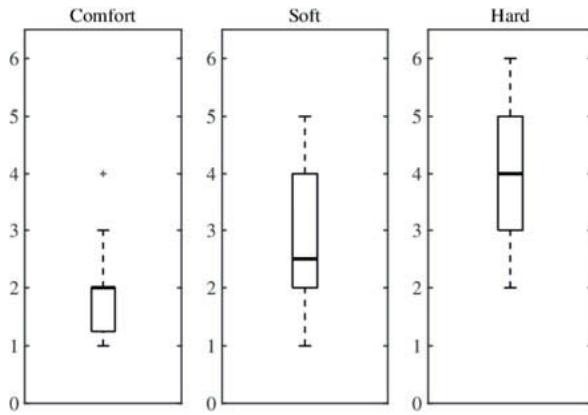


Fig. 5: Subjective Values for in Study I [21]

In order to investigate the correlation between the estimated discomfort ratings and the subjective ratings, it is necessary that the objective values are mapped to a suitable discomfort rating scale, which is only the case for ISO-2631 [29], BS 6841 [7] and the method of Cucuz [13]. For the methods of Klingner [32] and Hennecke [28] the objective values of the different settings are all mapped to the same discomfort value, therefore there is no difference in the predicted subjective rating. For the method of Rericha [60] no estimated discomfort value could be calculated. Although this study was performed with a small sample size some conclusions can be drawn from the results. The standardized methods of ISO-2631 [29] (VDI-2057 [69]) and BS 6841 [7] deliver acceptable results in terms of the objective criterion and the mapping to the estimated discomfort value. The rank correlation coefficient Kendalls-Tau,

which is 0.46 for ISO-2631 [29] and 0.45 for BS 6841 [7] shows this as well. These values represent a strong correlation in behavioural sciences according to Cohen [12]. No correlation is found for the method of Cucuz [13] ( $r_b = -0.18$ ). These results coincide partially with the findings of Bitter [4]. He also investigated the methods of Klingner [32], Rericha [60], ISO-2631:1997 [29] and VDI-2057:2002 [68]). Bitter found best correlation for ISO-2631 [29], followed by the old VDI-2057:2002, Klingner [32] and Rericha [60]. Neglecting the old VDI standard, this order is confirmed within this study. However, Bitter used linear regression models which rely at least on interval-scaled data sets, which is not given due to the subjective ratings. Therefore this regression is possibly valid for the subjective rating scale used by Bitter, which is a grading scale from one to ten, but it is not possible to draw generalized conclusions. The strong correlation of the method by Rericha [60] could not be confirmed in this study. It was shown that the standards like ISO-2631 [29] are a good starting point for a general assessment of ride comfort. More detailed methods like the ones of Hennecke [28] and Klingner [32] show potential to improve the calculation of an objective value, but they lack a suitable mapping to an estimated discomfort value. The method of Cucuz [13] and Rericha [60] failed to show a consistent objective value for different settings in this study. Both methods were not able to predict a discomfort value, but this needs further investigation before a final conclusion can be drawn.

### Results: Body-Based Method

Tables 5 and 6 show the RMS values measured at the seat and head measurement point in Study II. Table 5 shows seat pad measurements of an attentive and an inattentive occupant averaged over all subjects. The  $\overline{RMS}^{(E)}$  (eq. 4) is shown together with the mean value of  $\Delta RMS$  and the percentage difference  $\overline{RMS}^{(D)}$  (eq. 5). Table 5 shows that test section three, the recently graded road, results in the lowest excitation for all three measurement directions. Section two shows the largest effective value for the vertical direction, and together with section four the largest effective value in the lateral direction. There is a small difference in the y-direction for all sections, which is most likely due to measurement accuracy, for example due to the placement of the seat pad. In section four the values for the seat-pad sensor of the inattentive occupant are lower than for the attentive one.

Tab. 5: Comparison of an attentive driver and inattentive passenger during a ride by RMS analysis of the seat cushion sensor

RMS	x			y			z		
	E $\frac{m}{s^2}$	$\Delta$ $\frac{m}{s^2}$	D %	E $\frac{m}{s^2}$	$\Delta$ $\frac{m}{s^2}$	D %	E $\frac{m}{s^2}$	$\Delta$ $\frac{m}{s^2}$	D %
Section 1	0.45	0.04	7.9	0.23	-0.004	-1.8	0.81	0.08	9.3
Section 2	0.53	0.16	30.3	0.33	-0.007	-2.1	0.94	0.32	34.6
Section 3	0.19	0.04	21.0	0.13	-0.008	-5.9	0.34	0.10	30.2
Section 4	0.46	-0.06	-13.3	0.37	-0.006	-1.6	0.85	-0.14	-16.0

In Table 6 it can be seen that the effective accelerations measured at the head are larger than the ones measured at the seat cushion, independent of the measurement direction. This effect is particularly visible in the longitudinal and lateral direction, where the percentage difference is large as well. Almost no increase can be seen in the vertical direction, even though the measured effective value is greater than the one measured at the seat. The human anatomy is a possible explanation for this. The movement of the head-neck complex is less limited around the longitudinal and lateral axis, as it is easy to tilt the head sideways and forward/backward. Additionally, the combination of seat and seat-belt in most passenger cars allows some movement of the occupant torso. The vertical direction is restricted due to the human spine, independent of the state of attention. In section four, the vertical RMS acceleration is lower for the passenger, which is consistent with the seat-pad sensor. The values for the x- and y- direction are higher compared to the attentive driver.

Tab. 6: Comparison of an attentive driver and inattentive passenger during a ride by RMS analysis of the head cap sensor

RMS	x			y			z		
	E $\frac{m}{s^2}$	$\Delta$ $\frac{m}{s^2}$	D %	E $\frac{m}{s^2}$	$\Delta$ $\frac{m}{s^2}$	D %	E $\frac{m}{s^2}$	$\Delta$ $\frac{m}{s^2}$	D %
Section 1	0.91	0.41	44.9	0.49	0.10	20.8	1.15	0.29	20.7
Section 2	1.01	0.48	47.6	0.70	0.20	29.1	1.51	0.47	31.1
Section 3	0.46	0.27	59.7	0.35	0.08	22.6	0.52	0.14	26.9
Section 4	0.89	0.37	41.5	0.69	0.18	26.8	1.19	-0.06	-5.3

The collected survey data is presented in Figure 6. The scale extends from very comfortable with a value of one to very uncomfortable with a value of seven. The plots show the median, the lower (25%) and upper (75%) quartiles, the interquartile range and the span of the valid

ratings. Ratings outside the whiskers are outliers and thereby negligible. The ratings show, that the ride over section three, the recently graded road, is rated as the most comfortable section in both states of attention. Section four, the section with the highest excitation level results in the lowest ride comfort. In general, the inattentive subjective ratings are lower than the attentive ones for all sections.

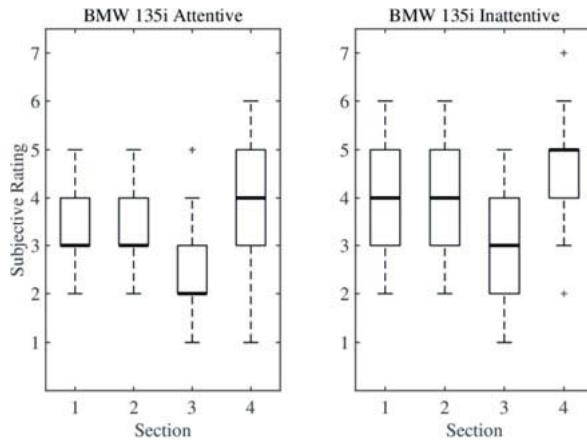


Fig. 6: Subjective results for the different states of attention in Study II

Table 7 shows the results of the Mann-Whitney U test. The different numbers result from the consistency test. The outliers (Figure 6) were not taken into account and the test shows that there is a significant difference between attentive and inattentive comfort ratings for all sections. The rank sum comparison across all sections shows a significant difference in the evaluation. The effect strength according to Pearson for all sections is 0.37 and corresponds to a medium effect.

Tab. 7: Mann-Whitney U test of the comfort ratings divided by sections

	count	r-sum	z-score	p	r	h
Section 1	39	1868	3.38	7.36e-4	0.54	1
Section 2	39	1779	2.46	13.8e-3	0.39	1
Section 3	36	1483	1.99	46.2e-3	0.33	1
Section 4	36	1481	1.99	46.9e-3	0.33	1
All. Sec.	150	25884	4.53	6.03e-6	0.37	1

The results show that a significant difference can be measured in the perception of comfort between an attentive and an inattentive state. Inattentive occupants experience the ride less comfortable than attentive occupants. This difference cannot be measured by using the vehicle body accelerations and is only visible in the x- and y- direction of the seat cushion sensor. The objective values according to ISO-2631 in Table 8 show higher discomfort ratings for the inattentive occupant in sections one, two and three. In the fourth section, the ISO value predicts higher discomfort for the driver, which is opposing the subjective ratings. Previous studies have shown that occupants are particularly sensitive to lateral movements. The head accelerations, show a clear difference between an attentive and an inattentive occupant and correlate to the subjective ratings. It is supposed that the increased head movement of the occupant could be linked to a reduced driving comfort. This suggests that the head should be considered as an additional measurement point for objectifying autonomous driving comfort in the future.

Tab. 8: Objective values ( $a_{ges}$  in  $\frac{m}{s^2}$ ) and their standard deviation according to ISO-2631 in Study II, calculated for the attentive driver (at), inattentive co-driver (in) and the vehicle (ve)

	$\mu^{(at)}$	$\sigma^{(at)}$	$\mu^{(in)}$	$\sigma^{(in)}$	$\mu^{(ve)}$	$\sigma^{(ve)}$
<b>Section 1</b>	0.66	0.12	0.74	0.08	0.54	0.05
<b>Section 2</b>	0.71	0.13	1.01	0.09	0.71	0.04
<b>Section 3</b>	0.28	0.03	0.37	0.03	0.26	0.01
<b>Section 4</b>	0.88	0.13	0.76	0.08	0.63	0.06

## Conclusion and Outlook

The comparison of conventional methods showed that the ISO-2631 [29], the VDI-2057 [69] and the BS 6841 [7] are most suitable to predict ride comfort in passenger cars. The methods of Hennecke [28], Rericha [60], Klingner [32] and Cucuz [13], which try to improve correlation by using additional signals and different weighing functions, could not show any improvement and performed worse than the standards. The method of Klingner [32] is able to show objective values that represent the same order as the subjective ratings, but lacks an estimation for the subjective rating. The method is also worse at distinguishing different damper settings compared to the standards. The method of Hennecke [28] shows the most consistent objective ratings for a certain damper settings, but also lacks an estimation for a subjective rating. Additionally, it shows the best objective value for the soft damper setting,

which is wrong as this setting is only rated second best by the subjects. The methods of Rericha [60] and Cucuz [13] fail to show consistent objective values and are therefore not recommended to use. In case of the method according to Rericha [60], it is possible that the low resolution steering angle signal and its noisy second derivative has influenced the results in a negative way. Measurements with the body measurement system show that inattentive occupants of passenger cars perceive larger RMS accelerations at the head compared to attentive ones. This can also be seen in the vehicle to head transmissibility in Figure 7 in the appendix. Compared to the attentive driver, the inattentive passenger has higher amplification in the z-direction around 4 Hz and in pitch (rotation around y-axis) in between 5 to 8 Hz. The subjective ratings of passengers in a real test vehicle show lower scores of inattentive occupants compared to attentive ones. A thorough literature review shows that there are currently no objectification methods that allow to distinguish between attentive and inattentive occupants. The ISO values of Table 8 predict higher discomfort for the inattentive occupant in three out of four sections. Looking at the vehicle to seat transmissibility in Figure 8 in the appendix, it can be seen that the most notable difference is in the vertical acceleration in between 4 to 10 Hz, which is also the most sensible frequency range according to the ISO-2631. For section four, the RMS values of the seat cushion sensor and therefore the calculated discomfort value according to ISO-2631 are lower for the inattentive passenger. But also on this section the subjective ratings are worse for the inattentive ones. Opposite to the seat pad sensor, the RMS accelerations values at the head sensor are higher for the inattentive person. The subjective ratings correlate to the acceleration values measured at the head of the occupants. In future studies, the influence of the degree of attention on the perceived ride comfort needs to be investigated. It is expected that the susceptibility to vibrations is depending on the activity of a passenger, for example if the activity involves hand-eye coordination the passenger might be more sensitive compared to a situation where he is watching a movie. Also the seating posture during an activity might be important to consider. In Study II, there was only an attentive driver and an inattentive co-driver. It is therefore possible that differences in the subjective and objective ratings are compromised by the position of the test person in the vehicle. The pure influence of the degree of attention needs to be verified in future studies, where the excitation is exactly the same, for example in a driving simulator. Based on the findings of this research, it is suggested to use the head of a test person as additional measuring point for objectification of ride comfort in autonomous cars and other vehicles. Determining suitable filter functions and weighing parameters for the new measurement point, as well as their validation remain as future tasks.

## Acknowledgements

The studies and corresponding results described in this paper are part of a research collaboration between the Bayerische Motoren Werke AG (BMW) and the Technical University of Munich (TUM). In this context the authors want to thank Sven Löffler and Dominic Neumann for their help in the assessment and evaluation of the study data. Further we want to thank Nathan Munzinger and Dr.-Ing. Serge Vos from BMW Group for their advice and valuable input. The content of this paper is published as original work in the Journal "Forschung im Ingenieurwesen" and was presented at AUTOREG 2019 in Mannheim, Germany.

## Disclosure Statement

The authors declare that they have no conflict of interest.

## Funding

This research was funded by Bayerische Motoren Werke AG.

## Contributions

First author Erik Enders was initiator of Study I and was involved in planning, preparation, conduct and analysis of both studies. Second author Georg Burkhard was initiator of Study II, responsible for the body based objectification approach and performed in-depth analysis of Study II. Third author Felix Fent designed Study I together with the first author and conducted the study within the scope of his thesis work. Markus Lienkamp and Dieter Schramm made essential contributions to the conception of the research project and revised the paper critically for important intellectual content. Markus Lienkamp and Dieter Schramm gave final approval of the version to be published and agree to all aspects of the work. As guarantors, they accept responsibility for the overall integrity of the paper.

- [1] Ammon, D., Frank, P., Gimmler, H., Götz, J., Hilf, K.D., Rauh, J., Scheible, G., Stiess, P.: Fahrzeugschwingungen - Von der Fahrbahnanregung bis zum Komfortempfinden. VDI-Tagung Humanschwingungen pp. 139–158 (2004)
- [2] Bellmann, M.A., Remmers, H., Mellert, V.: Grundlegende Experimente zur Wahrnehmung von vertikalen Ganzkörpervibrationen. In: VDI-Verlag (ed.) Humanschwingungen, VDI-Berichte, pp. 1–20. VDI-Verl., Düsseldorf (2004)
- [3] Berberich, T.: Subjektive Schwingungskomfortbewertung in einem Simulator. Dissertation, TU München, München (2016)
- [4] Bitter, T.: Objektivierung des dynamischen Sitzkomforts: Zugl.: Braunschweig, Techn. Univ., Diss., 2006, Schriftenreihe des Instituts für Fahrzeugtechnik TU Braunschweig, vol. 9. Shaker, Aachen (2006)
- [5] Boileau, P.É., Rakheja, S.: Whole-body vertical biodynamic response characteristics of the seated vehicle driver. International Journal of Industrial Ergonomics 22(6), 449–472 (1998)
- [6] Bress, H.J.: Messung von Humanschwingungen. In: W. Stühler (ed.) Fahrzeug Dynamik, pp. 152–177. Vieweg+Teubner Verlag, Wiesbaden and s.l. (1988)
- [7] British Standards Institution: BS 6841 – Guide to measurement and evaluation of human exposure to whole-body mechanical vibration and repeated shock. (1987)
- [8] Bubb, H., Bengler, K., Grünen, R.E., Vollrath, M.: Automobilergonomie. Springer Fachmedien Wiesbaden, Wiesbaden (2015)
- [9] Burkhard, G., Enders, E., Vos, S., Munzinger, N., Schramm, D.: Acquiring requirements on drive comfort by quantifying the accelerations affecting vehicle occupants. In: AmE 2018 – Automotive meets Electronics; 9th GMM-Symposium, pp. 1–6 (2018)

- [10] Burkhard, G., Vos, S., Munzinger, N., Enders, E., Schramm, D.: Requirements on driving dynamics in autonomous driving with regard to motion and comfort. In: M. Bargende, H.C. Reuss, J. Wiedemann (eds.) 18. Internationales Stuttgarter Symposium, Proceedings, pp. 683–697. Morgan Kaufmann, [S.I.] (2018)
- [11] Cleff, T.: Deskriptive Statistik und Explorative Datenanalyse: Eine computergestützte Einführung mit Excel, SPSS und STATA. Gabler Verlag, Wiesbaden (2015)
- [12] Cohen, J.: Statistical Power Analysis for the Behavioral Sciences, 2nd ed. edn. Taylor and Francis, Hoboken (1988)
- [13] Cucuz, S.: Schwingempfindung von Pkw-Insassen: Auswirkung von stochastischen Unebenheiten und Einzelhindernissen der realen Fahrbahn. Dissertation, TU Braunschweig, Braunschweig (1993)
- [14] DeShaw, J., Rahmatalla, S.: Comprehensive measurement in whole-body vibration. Journal of Low Frequency Noise, Vibration and Active Control 31(2), 63–73 (2012)
- [15] DeShaw, J., Rahmatalla, S.: Predictive discomfort in single-and combined-axis whole-body vibration considering different seated postures. Human factors 56(5), 850–863 (2014)
- [16] DeShaw, J., Rahmatalla, S.: Predictive discomfort of supine humans in whole-body vibration and shock environments. Ergonomics 59(4), 568–581 (2016)
- [17] Dewangan, K.N., Rakheja, S., Marcotte, P.: Gender and anthropometric effects on whole-body vibration power absorption of the seated body. Journal of Low Frequency Noise, Vibration and Active Control 37(2), 167–190 (2018)
- [18] Dungs, J., Herrmann, F., Duwe, D., Schmidt, A., Stegmüller, S. and Gay-Doul, R., Peters, P. L., Sohl, M.: The value of time: Nutzer bezogene service-potenziale durch autonomes fahren. Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO and Horváth & Partners (2016)

- [19] Eisenbarth, M., Boisdequin, G., Gauterin, F.: Consistent assessment of chassis relevant ride comfort on roads and test rigs. In: M. Bargende, H.C. Reuss, J. Wiedemann (eds.) 14. Internationales Stuttgarter Symposium, Proceedings, pp. 847–859. Springer Fachmedien Wiesbaden, Wiesbaden (2014)
- [20] Endsley, M.R.: Situation awareness in future autonomous vehicles: Beware of the unexpected. In: S. Bagnara, R. Tartaglia, S. Albolino, T. Alexander, Y. Fujita (eds.) Proceedings of the 20th Congress of the International Ergonomics Association (IEA2018), Advances in Intelligent Systems and Computing, vol. 824, pp. 303–309. Springer International Publishing, Cham (2019)
- [21] Fent, F.: Objektivierung von Vertikaldynamikkomfort in Personenkarawagen. Bachelorarbeit, Technische Universität München (2018)
- [22] Festner, M., Baumann, H., Schramm, D.: Der Einfluss fahrfremder Tätigkeiten und Manöverlängsdynamik auf die Komfort- und Sicherheitswahrnehmung beim hochautomatisierten Fahren — Ein Argument für die Adaptivität automatisierter Fahrfunktionen. VDI-Berichte 32(2288), 121–130 (2016)
- [23] Festner, M., Eicher, A., Schramm, D.: Beeinflussung der Komfort- und Sicherheitswahrnehmung beim hochautomatisierten Fahren durch fahrfremde Tätigkeiten und Spurwechseldynamik. Uni-DAS 11. Workshop Fahrerassistenzsysteme und automatisiertes Fahren (2017)
- [24] Fritzsche, F.: Software-Schwingungs-Dummy. In: Darstellung des Schwingungsverhaltens von Fahrzeug-Insassen, FAT-Schriftenreihe, vol. 189, pp. 230–276. Forschungsvereinigung der Automobiltechnik e.V. (2005)
- [25] Gohari, M., Rahman, R.A., Raja, R.I., Tahmasebi, M.: A Novel Artificial Neural Network Biodynamic Model for Prediction Seated Human Body Head Acceleration in Vertical Direction. Journal of Low Frequency Noise, Vibration and Active Control 31(3), 205–216 (2012)
- [26] Griffin, M.J.: Handbook of Human Vibration. Academic Press, London (1990)

- [27] Griffin, M.J.: Discomfort from feeling vehicle vibration. *Vehicle System Dynamics* 45(7-8), 679–698 (2007)
- [28] Hennecke, D.: Zur Bewertung des Schwingungskomforts von Pkw bei instationären Anregungen, *Fortschritt-Berichte VDI Reihe 12, Verkehrstechnik, Fahrzeugtechnik*, vol. 237, als ms. gedr edn. VDI-Verl., Düsseldorf (1995)
- [29] International Organization for Standardization: ISO-2631 – Mechanical vibration and shock - Evaluation of human exposure to whole-body vibration - Part 1: General requirements (1997)
- [30] International Organization for Standardization: ISO-10326 – Mechanical vibration – Laboratory method for evaluating vehicle seat vibration – Part 1: Basic requirements (2016)
- [31] Jörissen, B.: Objektivierung der menschlichen Schwingungswahrnehmung unter Einfluss realer Fahrbahnanregungen: Zugl.: Duisburg-Essen, Univ., Diss., 2012. *Berichte aus der Fahrzeugtechnik*. Shaker, Aachen (2012)
- [32] Klingner, B.: Einfluss der Motorlagerung auf Schwingungskomfort und Geräuschanregung im Kraftfahrzeug. *Dissertation*, TU Braunschweig, Braunschweig (1996)
- [33] Knauer, P.: Objektivierung des Schwingungskomforts bei instationärer Fahrbahnanregung. *Dissertation*, TU München, München (2010)
- [34] Kosfelder, M.: Die Objektivierung des Schwingungskomforts von Kraftfahrzeugen auf der Grundlage globaler Bewegungsformen. In: *Tagungsband 14. Aachener Kolloquium Fahrzeug- und Motorentechnik*, pp. 1631–1644. fka - Forschungsgesellschaft Kraftfahrtwesen mbH, Aachen (2005)
- [35] Kosfelder, M., Periard, F.: Ein modalanalytischer Ansatz zur Bestimmung der globalen Bewegungsformen von Kraftfahrzeugen. Teil II: Verifikation und Anwendungen. In: U. Jekosch (ed.) *Fortschritte der Akustik; DAGA '02, Fortschritte der Akustik*, pp.174–175. Dt. Ges. für Akustik, Oldenburg (2002)

- [36] Krist, R.: Modellierung des Sitzkomforts: Eine experimentelle Studie: Zugl.: Eichstätt, Kath. Univ., Diss., 1993. Schuch, Wei-den (1994)
- [37] Kudritzki, D.K.: Ridemeter – Calculated Ride Comfort. SAE Technical Paper (2007)
- [38] Lee, R.A., Pradko, F.: Analytical Analysis of Human Vibration. In: SAE Technical Paper Series, SAE Technical Paper Series. SAEInternational400 Commonwealth Drive, Warrendale, PA, United States (1968)
- [39] Lennert, S.: Zur Objektivierung von Schwingungskomfort in Personenkarfreitwagen: Untersuchung der Wahrnehmungsdimensionen, Fortschritt-Berichte VDI Reihe 12, Verkehrstechnik/Fahrzeugtechnik, vol. 698, als ms. gedr edn. VDI-Verl., Düsseldorf (2009)
- [40] Lennert, S., Wölfel, H.P.: Ansatz zur Objektivierung von Schwingungskomfort und Erläuterung anhand eines Praxisbeispiels. In: Humanschwingungen, VDI-Berichte, vol. 2002, pp.215–228. VDI-Verl., Düsseldorf (2007)
- [41] de Looze, M.P., Kuijt-Evers, L.F.M., van Dieen, J.: Sitting comfort and discomfort and the relationships with objective measures. Ergonomics 46(10), 985–997 (2003)
- [42] Mansfield, N.J.: Human response to vibration. Taylor & Francis, Boca Raton (2005)
- [43] Mansfield, N.J., Maeda, S.: Subjective ratings of whole-body vibration for single- and multi-axis motion. The Journal of the Acoustical Society of America 130(6), 3723–3728 (2011)
- [44] Maslow, A.: Motivation und Persönlichkeit, 2325 edn. Rororo-Sachbuch. Rowohlt Verlag (1991)
- [45] Matsumoto, Y., Maeda, S., Iwane, Y., Iwata, Y.: Factors affecting perception thresholds of vertical whole-body vibration in recumbent subjects: Gender and age of subjects, and vibration duration. Journal of Sound and Vibration 330(8), 1810–1828 (2011)

- [46] Mitschke, M., Klingner, B.: Schwingungskomfort im Kraftfahrzeug. ATZ - Automobiltechnische Zeitschrift 100(1), 18–24 (1998)
- [47] Mitschke, M., Wallentowitz, H.: Dynamik der Kraftfahrzeuge. Springer Fachmedien Wiesbaden, Wiesbaden (2014)
- [48] Moser, U.: The use of multivariate dynamic time warping to determine the most influential variables in adas comfort perception. The 14th International Symposium on Advanced Vehicle Control (AVEC) (2018)
- [49] Mozaffarin, A., Pankoke, S., Bersinger, F., Cullmann, A.: MEMOSIK®: Entwicklung und Einsatz eines aktiven, 3-dimensionalen Dummys zur Messung des Schwingungskomforts auf Fahrzeugsitzen. In: Humanschwingungen, VDI-Berichte, pp.481–509. VDI-Verl., Düsseldorf (2007)
- [50] Nguyen, M.T., Pitz, J., Krantz, W., Neubeck, J., Wiedemann, J.: Subjective Perception and Evaluation of Driving Dynamics in the Virtual Test Drive. SAE International Journal of Vehicle Dynamics, Stability, and NVH 1(2) (2017)
- [51] Novitski, S.: Model S mit Allradantrieb und 700 PS (2014). URL: <http://www.autobild.de/artikel/tesla-model-s-p85d-vorstellung-5360568.html>
- [52] Paddan, G.S., Holmes, S.R., Mansfield, N.J., Hutchinson, H., Arrowsmith, C.I., King, S.K., Jones, R.J.M., Rimell, A.N.: The influence of seat backrest angle on human performance during whole-body vibration. Ergonomics 55(1), 114–128 (2012)
- [53] Paddan, G.S., Mansfield, N.J., Arrowsmith, C.I., Rimell, A.N., King, S.K., Holmes, S.R.: The influence of seat backrest angle on perceived discomfort during exposure to vertical whole-body vibration. Ergonomics 55(8), 923–936 (2012)
- [54] Periard, F., Kosfelder, M.: Ein modalanalytischer Ansatz zur Bestimmung der globalen Bewegungsformen von Kraftfahrzeugen. Teil I: Methode. In: U. Jekosch (ed.) Fortschritte der Akustik; DAGA '02, Fortschritte der Akustik, pp. 172–173. Dt. Ges. für Akustik, Oldenburg (2002)

- [55] Potor, M.: Eine kurze Geschichte der autonomen Fahrzeuge (2017). URL: <https://mobilitymag.de/geschichte-der-autonomen-fahrzeuge/>
- [56] Rahmatalla, S., Xia, T., Ankrum, J., Wilder, D., Law, L.F., Abdel-Malek, K., Contratto, M., Kopp, G.: A framework to study human response to whole body vibration. In: SAE Technical Paper Series, SAE Technical Paper Series. SAE International 400 Commonwealth Drive, Warrendale, PA, United States (2007)
- [57] Rakheja, S., Dong, R.G., Patra, S., Boileau, P.É., Marcotte, P., Warren, C.: Biodynamics of the human body under whole-body vibration: Synthesis of the reported data. *International Journal of Industrial Ergonomics* 40(6), 710–732 (2010)
- [58] Ramier, T.: Development of a Ridemeter: Research of methods and parameters to correlate ride comfort measures and subjective assessments inside vehicles. Master Thesis, CHALMERS, Göteborg (2008)
- [59] Reichart, U.: Objektive Kriterien für Langstreckenkomfort. Dissertation, TU Berlin, Berlin (2013)
- [60] Rericha, I.: Methoden zur objektiven Bewertung des Fahrkomforts. *Automobil Industrie* 31(2), 175–182 (1986)
- [61] Schwarz, N., Knauper, B., Hippler, H.J., Noelle-Neumann, E., Clark, L.: Rating scales: Numeric values may change the meaning of scale labels. *Public Opinion Quarterly* 55(4), 570 (1991)
- [62] Sedlmeier, P., Renkewitz, F.: *Forschungsmethoden und Statistik in der Psychologie*, [nachdr.] edn. PS Psychologie. Pearson Studium, München (2011)
- [63] Simic, D.: Beitrag zur Optimierung der Schwingungseigenschaften des Fahrzeugs. Dissertation, TU Berlin, Berlin (1970)
- [64] Smith, C.C., McGehee, D.Y., Healey, A.J.: The Prediction of Passenger Riding Comfort from Acceleration Data. *Journal of Dynamic Systems, Measurement, and Control* 100(1), 34 (1978)

- [65] Stammen, K.: Bewertung des Schwingungskomforts in PKW mit Hilfe von Regressionsmodellen und künstlichen neuronalen Netzen: Zugl.: Hamburg, Helmut-Schmidt-Univ., Diss., 2009, Fortschritt-Berichte VDI Reihe 12, Verkehrstechnik/Fahrzeugtechnik, vol. 710, als ms. gedr edn. VDI-Verl., Düsseldorf (2009)
- [66] Strandemar, K., Thorvald, B.: Ride diagram. A tool for analysis of vehicle suspension settings. Vehicle System Dynamics 44(sup1), 913–920 (2006)
- [67] Trommer, S., Kolarova, V., Fraedrich, E., Kröger, L.: Autonomous driving: The impact of vehicle automation on mobility behavior (2016)
- [68] VDI-Fachbereich Schwingungstechnik: VDI-2057 – Einwirkung mechanischer Schwingungen auf den Menschen - Ganzkörper-Schwingungen (2002)
- [69] VDI-Fachbereich Schwingungstechnik: VDI-2057 – Einwirkung mechanischer Schwingungen auf den Menschen - Ganzkörper-Schwingungen (2017)
- [70] Zhang, L., Helander, M.G., Drury, C. G.: Identifying Factors of Comfort and Discomfort in Sitting. Human Factors: The Journal of the Human Factors and Ergonomics Society38 (3), 377–389(1996)

## Appendix

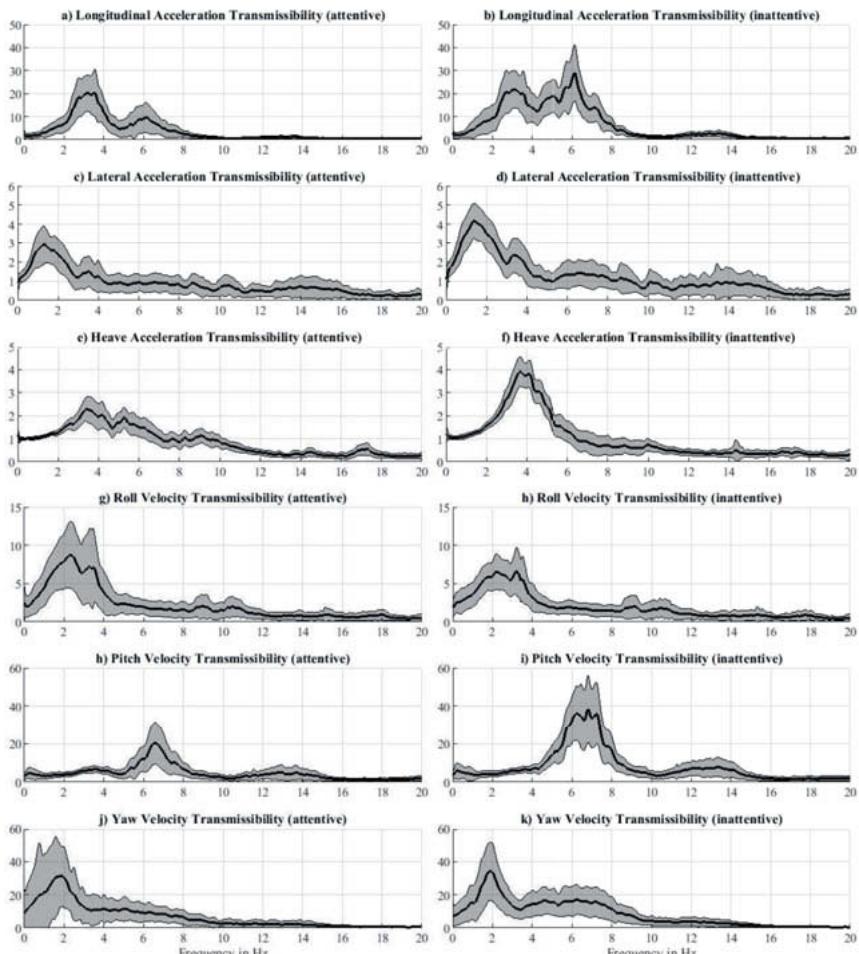


Fig. 7: Vehicle to Head Transmissibility (different y-axis scaling depending on the direction)

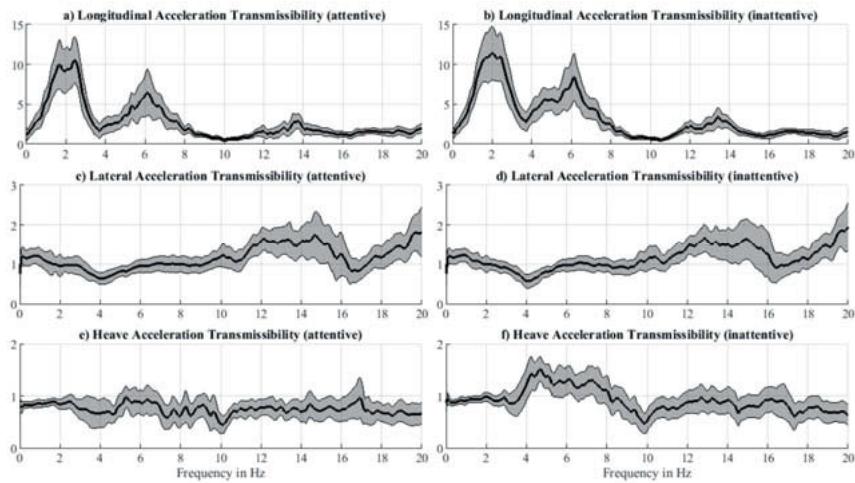


Fig. 7: Vehicle to Seat Transmissibility (different y-axis scaling depending on the direction)

# Kooperative Steuerung vernetzter Fahrzeuge

**Alexander Schwab, M.Sc., Prof. Dr.-Ing. Jan Lunze,**

Lehrstuhl für Automatisierungstechnik und Prozessinformatik (ATP),  
Ruhr-Universität Bochum

## Kurzfassung

Dieser Beitrag beschreibt ein neues Verfahren für die kooperative Steuerung vernetzter Fahrzeuge, mit der das Zusammenführen von Fahrzeugkolonnen automatisch erfolgt, indem auf kooperative Weise durch gezielte Kommunikation eine Lücke erzeugt wird, in die ein Fahrzeug aus der Nebenspur einscheren kann. Entsprechend einer allgemeinen Strategie zur Regelung von Multiagentensystemen werden zunächst Forderungen an das Gesamtsystem aufgestellt und daraus Bedingungen an die Teilsysteme abgeleitet. Es wurde gezeigt, dass eine extern positive Dynamik der Fahrzeuge notwendig und hinreichend dafür ist, Kollisionsfreiheit in der Kolonne zu garantieren. Dies hat zur Folge, dass die lokalen Regler so entworfen werden müssen, dass die Fahrzeuge das geforderte Verhalten unabhängig von der Art der verwendeten Modelle aufweisen. Diese Vorgehensweise wird hier auf den Einfädelvorgang erweitert.

## Abstract

The present paper describes a new cooperative control approach to merge multiple vehicle platoons automatically by creating a gap in the main lane, which is large enough to contain an additional vehicle. For this purpose, the vehicles are equipped with communication systems to cooperate with each other. The merging problem is solved with strategies of the control of multi-agent systems. The requirements on the behaviour of the overall system are translated into requirements on the controlled subsystems and the communication structure. It was shown that externally positive dynamics of the vehicles is necessary and sufficient in order to achieve collision avoidance. Thus, the local controllers have to be designed, so that the vehicles possess the imposed behaviour independently of the vehicle models. This technique is extended to the vehicle merging problem in this paper.

## 1 Einleitung

### 1.1 Fahrzeuge als vernetztes Regelungssystem

Moderne Fahrzeuge verfügen über eine Vielzahl von Fahrerassistenzsystemen wie zum Beispiel den sogenannten Abstandsregeltempomaten (engl. adaptive cruise control, ACC). Die Aufgabe solcher Systeme ist es, dafür zu sorgen, dass ein vorbestimmter Mindestabstand zum vorausfahrenden Fahrzeug nicht unterschritten wird. Fortschritte in der Entwicklung autonomer Fahrzeuge machen es darüber hinaus bereits heute möglich, automatische Spurwechselmanöver durchzuführen. Voraussetzung dafür ist es jedoch, dass eine hinreichend große Lücke auf der Zielfahrbaahn vorhanden ist, was bei dichtem Verkehr nur selten gewährleistet ist. Dieser Beitrag stellt daher eine Methode vor, die es digital vernetzten Fahrzeugen ermöglicht, auf kooperative Art und Weise eine Lücke auf der Hauptspur (Fahrtrichtung links) zu erzeugen, in die ein Fahrzeug von der Nebenspur (Fahrtrichtung rechts) einscheren kann, um eine Fahrbahnzusammenführung zu durchqueren. Dazu werden die Fahrzeuge als vernetztes Regelungssystem aufgefasst (Abbildung 1).

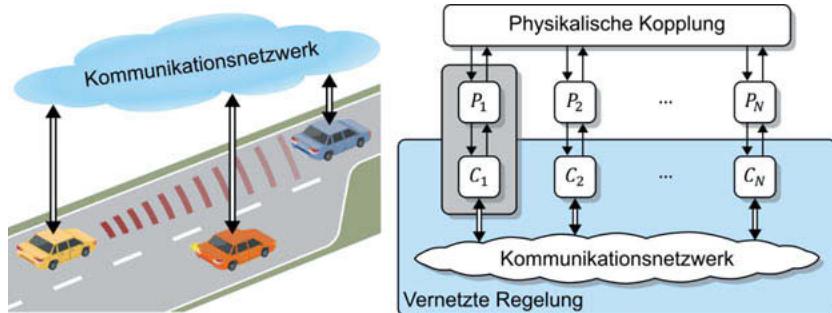


Abbildung 1: Kooperative Fahrzeuge als vernetztes Regelungssystem

In Abbildung 1 (links) sind drei Fahrzeuge dargestellt, die auf eine Fahrbahnzusammenführung zufahren. Alle Fahrzeuge verfügen über Sensoren, mit denen der Abstand zu vorausfahrenden Fahrzeugen gemessen werden kann, sowie über ein Kommunikationssystem, mit dem bei Bedarf zusätzliche Informationen mit anderen Fahrzeugen ausgetauscht werden können.

Systemtheoretisch wird die resultierende Struktur als vernetztes Regelungssystem interpretiert (Abbildung 1, rechts), bei dem jedes Fahrzeug  $P_i$  mit dem Regler  $C_i$  eine lokal geregelte Einheit bildet. Durch die gemeinsame Aufgabe, die Abstände zueinander zu regeln, entsteht eine Verkopplung der Teilsysteme, d. h. die physikalische Kopplung wird durch den Anwender eingeführt und ist daher, im Gegensatz zu klassischen physikalisch gekoppelten Systemen

(z. B. Elektroenergienetze), flexibel. Darüber hinaus sind die lokalen Regler in der Lage, mit ausgewählten anderen Reglern zu kommunizieren, um zu kooperieren.

## 1.2 Literaturübersicht

Die kooperative Regelung von Fahrzeugen ist ein interessantes Anwendungsfeld für die Theorie vernetzter Regelungssysteme [1]. In [2] wird gezeigt, wie automatisierte und kooperative Konzepte in der Fahrzeugregelung den Verkehrsfluss verbessern. Dazu werden die Strategien zur Regelung von vernetzten Systemen auf unterschiedliche Verkehrsmanöver angewandt und gezeigt, dass eine extern positive Dynamik [3] der Teilsysteme notwendig und hinreichend für die Kollisionsvermeidung ist [4].

In [5] wurde ein kooperativer Abstandsregeltempomat (CACC) auf Basis digitaler Kommunikation anhand einer Fahrzeugflotte implementiert und erfolgreich erprobt. In diesem Beitrag wird diese Vorgehensweise auf den Einfädelprozess erweitert. Eine Übersicht über Konzepte zum Zusammenführen von Fahrzeugkolonnen vor Fahrbahnzusammenführungen wird in [6] gegeben, wobei die bisherigen Konzepte auf spezielle Modellstrukturen zurückgreifen. Dieser Beitrag verallgemeinert die Ergebnisse aus [7], so dass keine expliziten Modelle angenommen werden müssen. Dazu wird eine kooperative Vorsteuerung, basierend auf der Publikation [8], vorgestellt, die das Einfädelungsproblem löst.

## 1.3 Struktur des Beitrags

In Abschnitt 2 wird das Regelungstechnische Problem geschildert und die zugrundeliegenden Fahrzeugmodelle beschrieben. Abschnitt 3 behandelt die Regelung von Fahrzeugkolonnen und fasst Bedingungen zusammen, die durch die lokalen Regler erfüllt werden müssen. Das Einfädelungsproblem wird in Abschnitt 4 diskutiert und im Abschnitt 5 werden die vorgestellten Konzepte anhand von Simulationsergebnissen veranschaulicht.

## 2 Problemschilderung

### 2.1 Ziel der Regelung

In diesem Beitrag werden Fahrzeuge auf mehreren Spuren betrachtet, die auf eine Fahrbahnzusammenführung, wie in Abbildung 1 dargestellt, zufahren. Fahrzeuge auf derselben Spur werden in aufsteigender Ordnung  $i = 1, 2, \dots, N_1$  auf der Hauptspur und  $N_1 + 1, N_1 + 2, \dots, N_1 + N_2$  auf der Nebenspur nummeriert. Folglich ist das Fahrzeug  $i - 1$  der Vorgänger von Fahrzeug  $i$ . Die Geschwindigkeit und die Position wird durch  $v_i(t)$  bzw.  $s_i(t)$  bezeichnet. Im Abstand

$$d_i(t) = s_{i-1}(t) - s_i(t) - l_i, \quad (1)$$

aufeinanderfolgender Fahrzeuge ist ein Mindestabstand  $l_i$  berücksichtigt, der die individuelle Fahrzeulgänge einschließt (siehe Abbildung 2).

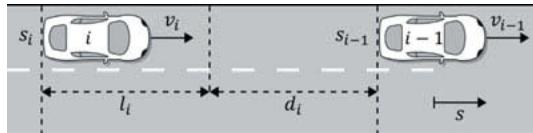


Abbildung 2: Zwei aufeinanderfolgende Fahrzeuge

**Abstandsregelung in Fahrzeugkolonnen.** Als erstes Problem wird eine Menge von Fahrzeugen betrachtet, die entlang einer Geraden fahren. Die lokalen Regler  $C_i$  sollen die Fahrzeuge so steuern, dass die Kolonne die folgenden Anforderungen erfüllt:

(F1) **Asymptotische Synchronisation:** Im stationären Zustand sollen alle Fahrzeuge mit derselben konstanten Referenzgeschwindigkeit  $v_0(t) = \bar{v}$  fahren:

$$\lim_{t \rightarrow \infty} |v_i(t) - v_0(t)| = 0, \quad i = 1, 2, \dots, N. \quad (2)$$

(F2) **Asymptotischer Zeitabstand:** Alle Fahrzeuge sollen einen Abstand einstellen, der über den Zeitabstandskoeffizienten  $\beta$  von der Geschwindigkeit abhängig ist:

$$\lim_{t \rightarrow \infty} |d_i(t) - \beta v_i(t)| = 0, \quad i = 2, 3, \dots, N. \quad (3)$$

(F3) **Kontinuierliche Progression:** Alle Fahrzeuge fahren jederzeit vorwärts, d. h.

$$v_i(t) \geq 0, \quad t \geq 0, \quad i = 1, 2, \dots, N. \quad (4)$$

(F4) **Kollisionsvermeidung:** Der Fahrzeugabstand muss jederzeit nicht-negativ sein

$$d_i(t) \geq 0, \quad t \geq 0, \quad i = 2, 3, \dots, N. \quad (5)$$

Die Anforderungen (F1)–(F4) müssen für den Entwurf der lokalen Regler  $C_i$  in Bedingungen an die geregelten Teilsysteme überführt werden.

**Steuerung vor einer Fahrbahnzusammenführung.** Der automatische Spurwechsel vor einer Fahrbahnzusammenführung wird als zweites Problem untersucht, wobei drei Fahrzeuge in der Konstellation von Abbildung 1 betrachtet werden. Das Fahrzeug  $j$  auf der Nebenspur muss aufgrund der Fahrbahnzusammenführung auf die Hauptspur wechseln. Da die Fahrzeuge  $i$  und  $i - 1$  auf der Hauptspur in einer Kolonne fahren, ist zwischen ihnen nicht ausreichend Platz für das zusätzliche Fahrzeug, so dass zunächst eine Lücke erzeugt werden muss. Für dieses Vorgehen sind die folgenden Schritte notwendig:

(S1) **Vorgänger auswählen:** Fahrzeug  $j$  muss aus der Kolonne auf der Hauptspur ein geeignetes Fahrzeugpaar ermitteln, zwischen die es einschalten kann, so dass Fahrzeug  $i - 1$  der neue Vorgänger von  $j$  wird.

- (S2) **Lücke erzeugen:** In einem abgeschlossenen Transitionsintervall  $\mathcal{T} = [t_0, t_e]$  verdoppelt Fahrzeug  $i$  den Abstand zu  $i - 1$ :

$$s_{i-1}(t_e) - s_i(t_e) = l_i + l_j + 2\beta\bar{v}. \quad (6)$$

- (S3) **Auf Lücke ausrichten:** Im gleichen Zeitintervall  $\mathcal{T}$  passt Fahrzeug  $j$  seinen Abstand zu Fahrzeug  $i - 1$  an, so dass die Forderung (F2) an den Zeitabstand erfüllt wird:

$$s_{i-1}(t_e) - s_j(t_e) = l_j + \beta\bar{v}. \quad (7)$$

- (S4) **Spurwechsel durchführen:** Nach dem Transitionsintervall kann Fahrzeug  $j$  auf die Hauptspur wechseln und wird Teil der Fahrzeugkolonne auf der Hauptspur.

Die Schritte (S2) und (S3) können simultan durchgeführt werden und erfordern, dass die Fahrzeuge ihren Abstand zum gemeinsamen Bezugsfahrzeug  $i - 1$  in endlicher Zeit anpassen. Gesucht ist folglich eine Steuerung, mit der die Fahrzeuge entlang einer Trajektorie  $d_i^*(t)$

$$d_i(t) = d_i^*(t), \quad t \in \mathcal{T} \quad (8)$$

geführt werden können. Da der Abstand (1) von der Position des Vorgängerfahrzeugs abhängig ist, kann diese Aufgabe nur *kooperativ* gelöst werden.

## 2.2 Mathematische Beschreibung von vernetzten Fahrzeugen

Die individuelle Fahrzeugdynamik wird durch das nicht gekoppelte Modell

$$\Sigma_i: \begin{cases} \dot{x}_i(t) = A_i x_i(t) + b_i u_i(t) \\ v_i(t) = c_i^T x_i(t), \quad x_i(0) = x_{i0} \end{cases} \quad (9)$$

beschrieben. Der Abstand zweier aufeinanderfolgender Fahrzeuge wird gemäß

$$d_i(t) = v_{i-1}(t) - v_i(t) = v_{i-1}(t) - c_i^T x_i(t) \quad (10)$$

von der Geschwindigkeitsdifferenz bestimmt. Gleichungen (9) und (10) liefern das Modell

$$P_i: \begin{cases} \begin{pmatrix} \dot{x}_i(t) \\ d_i(t) \end{pmatrix} = \begin{pmatrix} A_i & 0 \\ -c_i^T & 0 \end{pmatrix} \begin{pmatrix} x_i(t) \\ d_i(t) \end{pmatrix} + \begin{pmatrix} b_i \\ 0 \end{pmatrix} u_i(t) + \begin{pmatrix} 0 \\ 1 \end{pmatrix} v_{i-1}(t) \\ \begin{pmatrix} v_i(t) \\ d_i(t) \end{pmatrix} = \begin{pmatrix} c_i^T & 0 \\ 0^T & 1 \end{pmatrix} \begin{pmatrix} x_i(t) \\ d_i(t) \end{pmatrix}, \quad \begin{pmatrix} x_i(0) \\ d_i(0) \end{pmatrix} = \begin{pmatrix} x_{i0} \\ d_{i0} \end{pmatrix}, \end{cases} \quad (11)$$

aus dem hervorgeht, dass die Geschwindigkeit  $v_{i-1}(t)$  des vorausfahrenden Fahrzeugs als zusätzliche Eingangsgröße auf ein Teilsystem  $P_i$  wirkt.

## 3 Regelung von Fahrzeugkolonnen

Im Abschnitt 2.1 sind die Forderungen an das erwünschte Verhalten der geregelten Fahrzeugkolonne aufgeführt. Um diese Forderungen mit den lokalen Reglern  $C_i$  zu erfüllen, müssen diese Forderungen in Bedingungen an die geregelten Teilsysteme überführt werden. Dieser Schritt wird in [4] beschrieben und im Folgenden zusammengefasst.

### 3.1 Anforderungen an die Regelkreisstruktur

Die Forderungen (F1) und (F2) beschreiben das gewünschte asymptotische Verhalten der Kette, nachdem alle dynamischen Vorgänge abgeklungen sind, und lassen sich folglich in Anforderungen an die Struktur der lokalen Regler überführen. Die Geschwindigkeit  $v_i(t)$  und der Abstand  $d_i(t)$  zum vorausfahrenden Fahrzeug sind lokal messbare Größen, die zur Regelung herangezogen werden können und dementsprechend die Eingangsgrößen der Regler

$$C_i: \begin{cases} \dot{x}_{ri}(t) = A_{ri}x_{ri}(t) + B_{ri} \begin{pmatrix} v_i(t) \\ d_i(t) \end{pmatrix} \\ u_i(t) = c_{ri}^T x_{ri}(t) + d_{ri}^T \begin{pmatrix} v_i(t) \\ d_i(t) \end{pmatrix}, \quad x_{ri}(0) = x_{ri0} \end{cases} \quad (12)$$

bilden. Die Kombination aus dem Fahrzeugmodell (11) und dem Regler (12) liefert das Modell des geschlossenen Kreises mit der Eingangsgröße  $v_{i-1}(t)$  und den Ausgangsgrößen  $v_i(t)$  und  $d_i(t)$ . In [4] wird gezeigt, dass die Forderungen (F1) und (F2) erfüllt werden, wenn die statische Verstärkung des geregelten Fahrzeugs von der Eingangsgröße  $v_{i-1}(t)$  nach  $v_i(t)$  und  $d_i(t)$  gleich 1 bzw.  $\beta$  ist.

Die Betrachtung des statischen Verhaltens wird der einfacheren Analyse halber im Frequenzbereich durchgeführt. In der Frequenzbereichsdarstellung des Reglers (12)

$$C_i: \begin{cases} E_i(s) = \beta V_i(s) - D_i(s) \\ U_i(s) = K_i(s) E_i(s) \end{cases} \quad (13)$$

ist  $E_i(s)$  der Zeitabstandsfehler bezüglich der Forderung (F2). Das Übertragungsverhalten der gekoppelten Fahrzeuge (11)

$$P_i: \begin{cases} V_i(s) = G_i(s) U_i(s) \\ D_i(s) = 1/s (V_{i-1}(s) - V_i(s)) \end{cases} \quad (14)$$

wird durch die Übertragungsfunktion  $G_i(s)$  repräsentiert. Abbildung 3 zeigt das Blockschaltbild.

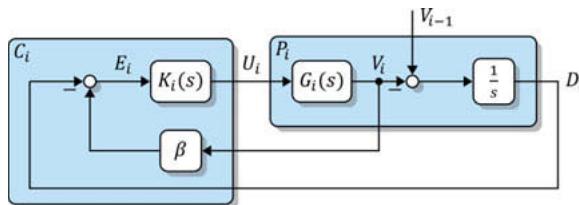


Abbildung 3: Regelkreis mit lokaler Abstandsregelung

Mit der offenen Kette  $G_{0i}(s) = G_i(s) \cdot K_i(s)$  lässt sich das Übertragungsverhalten des abgebildeten geschlossenen Kreises durch Umformung der Modellgleichungen (13) und (14) mit

$$V_i(s) = \frac{G_{0i}(s)}{G_{0i}(s)(\beta s + 1) - s} V_{i-1}(s) = \bar{G}_i(s) \cdot V_{i-1}(s) \quad (15)$$

$$D_i(s) = \frac{\beta \cdot G_{0i}(s) - 1}{G_{0i}(s)(\beta s + 1) - s} V_{i-1}(s) = G_{di}(s) \cdot V_{i-1}(s) \quad (16)$$

beschreiben. Für das statische Verhalten der Geschwindigkeit (15) erhält man

$$\bar{G}_i(0) = \frac{G_{0i}(0)}{G_{0i}(0)(\beta \cdot 0 + 1) - 0} = 1, \quad (17)$$

d. h. die Geschwindigkeit jedes Fahrzeugs stimmt asymptotisch mit der Geschwindigkeit des Vorgängers überein. Für den Abstand ergibt sich

$$G_{di}(0) = \frac{\beta \cdot G_{0i}(0) - 1}{G_{0i}(0)(\beta \cdot 0 + 1) - 0} = \beta - \frac{1}{G_{0i}(0)}. \quad (18)$$

Die Forderung  $G_{di}(0) = \beta$  lässt sich nur erfüllen, wenn die offene Kette mindestens einen Integrator enthält und entsprechend  $G_{0i}(s) = 1/s \tilde{G}_{0i}(s)$  faktorisiert werden kann. Dann gilt

$$G_{di}(0) = \left. \frac{\beta \cdot \tilde{G}_{0i}(s) - s}{\tilde{G}_{0i}(s)(\beta s + 1) - s^2} \right|_{s=0} = \beta \quad (19)$$

und daher  $d_i(t) = \beta v_{i-1}(t) = \beta v_i(t)$  für  $t \rightarrow \infty$ .

Insgesamt werden die Forderung (F1) und (F2) mit der in Abbildung 3 dargestellten Reglerstruktur, unabhängig von der Fahrzeugdynamik, erfüllt, wenn die offene Kette mindestens einen Integrator enthält und der Regelkreis durch  $C_i$  stabilisiert wird. Eine mögliche Realisierung des Reglers (13) ist der I-Regler

$$C_i: \begin{cases} \dot{x}_{ri}(t) = (\beta & -1) \begin{pmatrix} v_i(t) \\ d_i(t) \end{pmatrix} \\ u_i(t) = -k_{ri} x_{ri}(t), & x_{ri}(0) = x_{ri0}, \end{cases} \quad (20)$$

dessen Parameter  $k_{ri}$  so gewählt werden muss, dass der Regelkreis asymptotisch stabil ist.

### 3.2 Kollisionsvermeidung in der Fahrzeugkolonne

Die hier zugrundeliegende Idee ist, dass ein Fahrzeug seinem Nachfolger monoton folgen soll, was durch Erfüllung der Forderung

$$\sup_{t \geq 0} |v_i(t)| \leq \sup_{t \geq 0} |v_{i-1}(t)| \quad (21)$$

erreicht werden kann. Anschaulich bedeutet die Ungleichung (21), dass die Geschwindigkeit  $v_i(t)$  immer durch die Geschwindigkeit des vorausfahrenden Fahrzeugs beschränkt wird. Mit Hilfe der verallgemeinerten Young'schen Ungleichung lässt sich eine obere Schranke

$$\|v_i(t)\|_\infty \leq \|\bar{g}_i\|_1 \cdot \|v_{i-1}(t)\|_\infty \quad (22)$$

für die Norm der Faltung von  $v_{i-1}(t)$  mit der Gewichtsfunktion  $\bar{g}_i(t) \circ \bar{G}_i(s)$  angeben, mit der sich die Forderung (21) als Bedingung an die Gewichtsfunktion des geregelten Fahrzeugs

$$\|\bar{g}_i\|_1 = \int_0^\infty |\bar{g}_i(t)| dt \leq 1 \quad (23)$$

formulieren lässt. Aus (17) folgt

$$1 = \int_0^\infty \bar{g}_i(t) dt \leq \int_0^\infty |\bar{g}_i(t)| dt \leq 1, \quad (24)$$

wobei die Dreiecksungleichung für Integrale und die Forderung (23) genutzt wurde. Da auf beiden Seiten von Gl. (24) eine 1 steht, lässt sich die Bedingung nur dann erfüllen, wenn alle Beziehungen in (24) Gleichheiten sind, also wenn die Gewichtsfunktion nicht-negativ ist:

$$\bar{g}_i(t) \geq 0, \quad t \geq 0, \quad i = 1, 2, \dots, N \quad (25)$$

Ein System mit nicht-negativer Gewichtsfunktion wird *extern positiv* genannt. Solche Systeme haben die Eigenschaft, dass die Systemantwort für nicht-negative Eingangsgrößen und verschwindendem Anfangswert ebenfalls nicht-negativ ist. Für Fahrzeuge bedeutet dies, dass die Forderung (F3) erreicht wird, wenn Bedingung (25) erfüllt ist und die Geschwindigkeit des vorausfahrenden Fahrzeug nicht-negativ ist.

Mit den Gln. (14) und (15) erhält man die Gewichtsfunktion bezüglich des Abstands

$$g_{di}(t) = 1 - \int_0^t \bar{g}_i(\tau) d\tau, \quad t \geq 0 \quad (26)$$

mit  $g_{di}(t) \rightsquigarrow G_{di}(s)$  aus (16). Die Gln. (17) und (26) zeigten, dass  $g_{di}(t)$  nicht-negativ ist, wenn die Bedingung (25) erfüllt ist, d. h. Forderung (F4) wird automatisch erreicht, wenn (F3) erreicht wird. Das Ziel des Reglerentwurfs ist es folglich, eine nicht-negative Gewichtsfunktion  $\bar{g}_i(t)$  zu erhalten. Für zusätzliche Freiheitsgrade beim Entwurf kann der Regler (20) um die proportionalen Anteile  $k_{vi}$  und  $k_{di}$  erweitert werden:

$$C_i: \begin{cases} \dot{x}_{ri}(t) = (\beta - 1) \begin{pmatrix} v_i(t) \\ d_i(t) \end{pmatrix} \\ u_i(t) = -k_{ri}x_{ri}(t) - (k_{vi} - k_{di}) \begin{pmatrix} v_i(t) \\ d_i(t) \end{pmatrix}, \quad x_{ri}(0) = x_{ri0}. \end{cases} \quad (27)$$

Die Schwierigkeit beim Entwurf liegt darin, die Parameter  $k_{ri}$ ,  $k_{vi}$  und  $k_{di}$  so zu wählen, dass der geschlossene Kreis asymptotisch stabil und extern positiv ist.

## 4 Fahrzeugkoordination vor Fahrbahnzusammenführungen

### 4.1 Zielstellung und Lösungsweg

Im Folgenden werden Fahrzeuge betrachtet, die auf zwei parallelen Spuren auf eine Fahrbahnzusammenführung zufahren. Alle Fahrzeuge sind mit Abstandsreglern ausgestattet, die die im Abschnitt 3 genannten Bedingungen erfüllen.

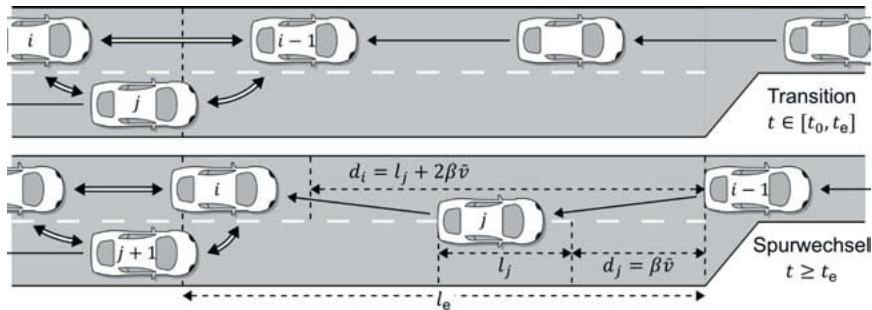


Abbildung 4: Kooperatives Einfädelungskonzept. Durchgezogene Pfeile und Doppelpfeile kennzeichnen Abstandsmessungen bzw. digitale Kommunikation.

Abbildung 4 zeigt die betrachtete Situation und skizziert den Lösungsansatz, der darin besteht, eine Lücke auf der Hauptspur zu erzeugen, bevor das einscherende Fahrzeug die Spur wechselt. Sobald ein Fahrzeug  $j$  auf der Nebenspur in den durch  $I_e$  gekennzeichneten Einfädelbereich einfährt, werden die Schritte (S1)–(S4) durchgeführt. Dazu werden vor dem eigentlichen Spurwechsel die Abstände der beteiligten Fahrzeuge

$$d_i(t) = d_i^*(t), \quad d_j(t) = d_j^*(t), \quad t \in \mathcal{T} = [t_0, t_e] \quad (28)$$

zueinander durch Steuerungen mit zweckmäßiger Trajektorienplanung so angepasst, dass eine Lücke zwischen den Fahrzeugen  $i$  und  $i - 1$  entsteht und Fahrzeug  $j$  sich mittig zur Lücke ausrichtet. Der Einfädelungsprozess lässt sich in drei zeitlich abgegrenzte Phasen aufteilen:

1. **Planungsphase:** Bevor Stelleingriffe vorgenommen werden ( $t < t_0$ ), erfolgt die Planung der Trajektorien und die Auswahl eines Fahrzeugaars auf der Hauptspur (S1). Es wird angenommen, dass dieser Schritt bei  $t = t_0$  abgeschlossen ist.
  2. **Transitionsphase:** Im Zeitintervall  $\mathcal{T}$  werden die geplanten Trajektorien von den Steuerungen umgesetzt, so dass Schritte (S2) und (S3) simultan durchgeführt werden.
  3. **Spurwechselphase:** Nach der Transitionsphase ( $t > t_e$ ) sind die Abstände zwischen den Fahrzeugen entsprechend der Zeitabstandsforderung (F2) eingestellt, so dass das Fahrzeug  $j$  auf der Nebenspur die Spur wechseln darf (S4).

Die kooperative Vorsteuerung ersetzt den Kolonnenregler während des Transitionintervalls  $T$ , um die geforderte Abstandsadaption durchzuführen, was aufgrund der Verkopplung der Fahrzeuge nur mit digitalen Kommunikationsverbindungen möglich ist.

## 4.2 Kooperative Vorsteuerung zur Abstandsadaption

Da der Fahrzeugabstand (10) von der Geschwindigkeit des vorausfahrenden Fahrzeugs abhängig ist, lässt sich die Anpassung dessen nicht isoliert für jedes Fahrzeug durchführen. Die

Idee der kooperativen Vorsteuerung basiert auf [8] und betrachtet die Steuerungsaufgabe (28) zunächst für den Fall, dass das Vorgängerfahrzeug stillsteht ( $v_{i-1}(t) = 0$ ) und modifiziert die Referenztrajektorie, so dass die Steuerungsaufgabe für beliebige Geschwindigkeiten  $v_{i-1}(t)$  erfüllt wird. Integration von (10) liefert

$$d_i(t) = d_{i0} - c_i^T \int_0^t x_i(\tau) d\tau + \int_0^t v_{i-1}(\tau) d\tau = \tilde{d}_i(t) + \int_0^t v_{i-1}(\tau) d\tau, \quad (29)$$

wobei  $\tilde{d}_i(t)$  den Teil der Ausgangsgröße beschreibt, der nicht von der Vorgängergeschwindigkeit  $v_{i-1}(t)$  abhängig ist. Die isolierte Regelungsaufgabe

$$\tilde{d}_i(t) = \tilde{d}_i^*(t) \quad (30)$$

lässt sich folglich mit einem beliebigen Vorsteuerungsentwurfsverfahren lösen. Um das ursprüngliche Problem (28) zu lösen, lässt sich die gewünschte Trajektorie  $d_i^*(t)$  gemäß

$$\tilde{d}_i^*(t) = d_i^*(t) - \int_0^t v_{i-1}^{\text{kom}}(\tau) d\tau \quad (31)$$

modifizieren, wobei  $v_{i-1}^{\text{kom}}(t)$  die über das digitale Kommunikationsnetz übermittelte Geschwindigkeit des vorausfahrenden Fahrzeugs bezeichnet. Wenn die kommunizierte Geschwindigkeit mit der tatsächlich gefahrenen Geschwindigkeit übereinstimmt

$$v_{i-1}^{\text{kom}}(\tau) = v_{i-1}(t) \quad (32)$$

und die lokale Steuerung die isolierte Aufgabe (30) löst, dann kompensiert die Referenzmodifikation (31) den Einfluss der Geschwindigkeit des Vorgängers in (29) und es gilt

$$d_i(t) = d_i^*(t), \quad (33)$$

d. h. das Regelungsziel (28) wird erreicht. Die Struktur der Steuerung ist in Abb. 5 dargestellt.

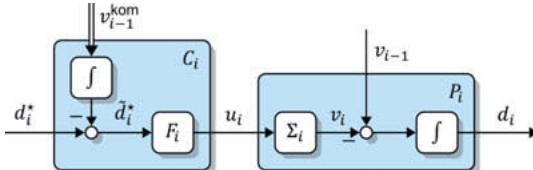


Abbildung 5: Kooperative Vorsteuerung

Die vorangegangenen Betrachtungen zeigen, dass die Geschwindigkeit des vorausfahrenden Fahrzeugs  $v_{i-1}(t)$  bekannt sein muss, um die Regelungsaufgabe zu lösen, weshalb sie während der Transitionsphase  $\mathcal{T}$  über das digitale Kommunikationsnetz übermittelt wird.

Der Entwurf der Steuerung  $F_i$  kann mit bekannten Methoden wie der inversionsbasierten oder flachheitsbasierten Vorsteuerungen erfolgen. Wenn die über das Kommunikationsnetz übermittelte Geschwindigkeit aufgrund von Paketausfällen, Verzögerungen in der Kommunikation oder Abweichungen durch Störungen oder Modellunbestimmtheiten nicht mit der tatsächlichen

Geschwindigkeit übereinstimmt, d. h. Bedingung (32) ist verletzt, kann die Vorsteuerung um eine zusätzliche Regelung zu einer Zwei-Freiheitsgrade-Regelung erweitert werden, die den Regelfehler  $e_i(t) = d_i(t) - d_i^*(t)$  stabilisiert [9].

### 4.3 Trajektorienplanung

Damit ein Fahrzeug seiner geplanten Trajektorie folgen kann, muss diese konsistent zu dem Zustand bei  $t = t_0$  sein. Diese Forderung lässt sich systemtheoretisch so formulieren, dass die Trajektorie und ihre  $r_i - 1$  ersten Ableitungen mit dem aktuellen Zustand übereinstimmen

$$d_i^{*(k)}(t_0) = d_i^{(k)}(t_0), \quad k = 0, 1, \dots, r_i - 1, \quad (34)$$

wobei  $r_i$  den relativen Grad des Fahrzeugs (11) bezeichnet [8].

Das Ziel der Transitionsphase ist es, die Abstände der beteiligten Fahrzeuge zur Zeit  $t = t_e$  so einzustellen, dass Schritte (S3) und (S4) erfüllt werden. Dazu werden die Forderungen

$$d_i^*(t_e) = \delta_e \quad (35)$$

$$d_i^{*(k)}(t_e) = 0, \quad k = 1, 2, \dots, r_i - 1, \quad (36)$$

an den Endzeitpunkt der Trajektorie gestellt, wobei  $\delta_e$  den Zielabstand bezeichnet und die Forderung (36) sicherstellt, dass der Zielzustand stationär ist, d. h. die Geschwindigkeit  $v_i(t)$  ändert sich nicht mehr. Die Zielabstände werden für die individuelle Aufgabe gewählt (vgl. Abbildung 4): Für Fahrzeug  $i$ , das eine Lücke erzeugen muss, gilt  $\delta_e = l_j + 2\beta\bar{v}$  und für das einscherende Fahrzeug  $j$  gilt  $\delta_e = \beta\bar{v}$ . Diese Forderungen lassen sich mit einem Polynom der Ordnung  $2r_i - 1$

$$d_i^*(t) = \sum_{k=0}^{2r_i-1} p_k t^k \quad (37)$$

erfüllen. Um Kollisionsvermeidung zu garantieren, müssen die Parameter  $p_k$  so gewählt werden, dass die Forderungen (34)–(36) erfüllt werden und der Verlauf von  $d_i^*(t)$  nicht-negativ ist (vgl. Abbildung 2). In [7] wird gezeigt, wie man diese Forderungen durch geeignete Wahl der Transitionszeit  $t_e - t_0$  erfüllen kann.

## 5 Simulationsstudie

Zur Veranschaulichung der vorgeschlagenen Konzepte werden insgesamt 50 identische Fahrzeuge, die durch das Modell

$$\begin{aligned} \Sigma_i: \begin{cases} \dot{x}_i(t) = -c/m \ x_i(t) + 1/m \ u_i(t) \\ v_i(t) = x_i(t) \end{cases} \end{aligned} \quad (38)$$

beschrieben werden, untersucht, wobei 30 Fahrzeuge auf der Hauptspur fahren und 20 auf der Nebenspur. Die verwendeten Parameter sind in Tabelle 1 aufgelistet.

Tabelle 1: Simulationsparameter

Parameter	$m$	$c$	$\beta$	$\bar{v}$	$l_i$	$t_e - t_0$
Wert	1000 kg	200 kg/s	1 s	20 m/s	20 m	20 s

Für die Abstandsregelung wird der Kolonnenregler (27) mit den Parametern  $k_{ri} = 9750 \text{ kg/s}^3$ ,  $k_{vi} = 8400 \text{ kg/s}$  und  $k_{di} = -11300 \text{ kg/s}^2$  verwendet, wodurch ein extern positiver Regelkreis entsteht. Während der Transitionsphase übernimmt die kooperative Vorsteuerung (s. Abbildung 5) die Steuerung des Fahrzeugs. Für den Entwurf von  $F_i$  kann ein inversionsbasierter Ansatz verfolgt werden, der auf Basis des Modells (38) das Stellgesetz

$$u_i(t) = m \cdot \dot{v}_i(t) + c \cdot v_i(t) \quad (39)$$

ergibt. Unter Ausnutzung von (10) erhält man

$$u_i(t) = -m \cdot \ddot{d}_i^*(t) - c \cdot \dot{\ddot{d}}_i^*(t) \quad (40)$$

mit  $\ddot{d}_i^*(t)$  aus Gleichung (31).

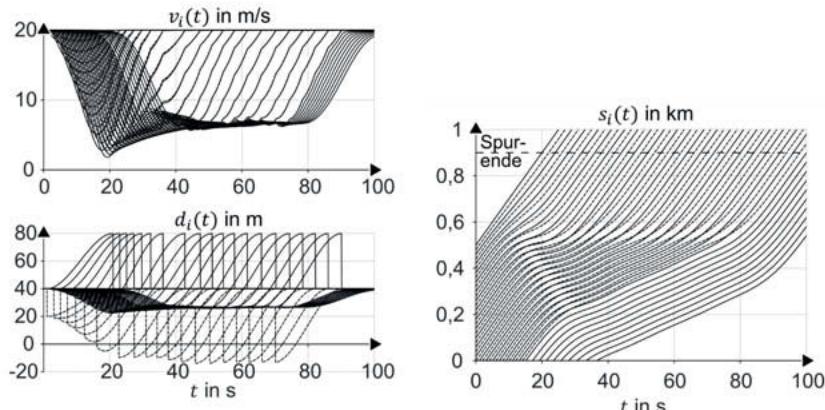


Abbildung 6: Geschwindigkeit, Abstand und Position der 50 Fahrzeuge

Abbildung 6 zeigt die Geschwindigkeiten, die Fahrzeugabstände und die Positionen aller Fahrzeuge. Die durchgezogenen Linien repräsentieren Fahrzeuge auf der Hauptspur und die gestrichelten Linien die Fahrzeuge auf der Nebenspur. Während der Transitionsphase verringern die Vorsteuerungen die Geschwindigkeiten der Fahrzeuge, um die Abstände entsprechend der Forderungen (35) und (36) anzupassen.

Nach der Transitionsphase werden die Kolonnenregler wieder aktiviert, wobei das zusätzlich eingefädelte Fahrzeug von der Nebenspur berücksichtigt wird, was zu den sprungförmigen Verlauf von  $d_i(t)$  führt. Die gestrichelten Linien in Abbildung 6 (unten links) repräsentieren nach dem Sprung den Abstand zwischen einem Fahrzeug auf der Hauptspur und auf der Nebenspur. Daher führt der negative Kurvenverlauf nicht zu Kollisionen.

Die resultierende Einfädelung ist in Abbildung 6 (rechts) dargestellt. Die individuelle Vorsteuerung wird immer dann aktiviert, wenn ein Fahrzeug in den Einfädelbereich bei 500 m einfährt. Aufgrund der gewählten Reisegeschwindigkeit  $\bar{v}$  ist der Einfädelprozess nach spätestens  $(t_e - t_0)\bar{v} = 400$  m bei der horizontalen gestrichelten Linie abgeschlossen. Danach werden die Kolonnenregler reaktiviert und es ist sicher, die Spur zu wechseln.

## 6 Zusammenfassung

Der vorliegende Beitrag präsentiert Lösungen für die Abstandsregelung von Fahrzeugkolonnen und das kooperative Zusammenführen mehrerer Kolonnen vor einer Fahrbahnzusammenführung. Dazu werden Fahrzeuge betrachtet, die über Abstandssensoren und ein Kommunikationssystem verfügen, das nur während des Einfädelprozesses genutzt wird. Bei den vorgestellten Ansätzen steht das grundlegende Konzept stets im Vordergrund und es wird auf explizite Modelle verzichtet, was dem Grundgedanken beim Entwurf vernetzter Systeme entspricht: Die Forderungen an das Gesamtsystem werden in Bedingungen an die Teilsysteme überführt, die durch lokale Regelungen erfüllt werden müssen, unabhängig von der Art oder Komplexität des Modells.

## Literaturverzeichnis

- [1] J. Lunze, *Networked Control of Multi-Agent Systems*, Bookmundo Direct, 2019.
- [2] B. van Arem, C. J. G. van Driel und R. Visser, „The impact of cooperative adaptive cruise control on traffic-flow characteristics,“ *IEEE Transactions on Intelligent Transportation Systems*, pp. 429-436, 2006.
- [3] L. Farina und S. Rinaldi, *Positive Linear Systems: Theory and Applications*, John Wiley & Sons, 2011.
- [4] J. Lunze, „Adaptive cruise control with guaranteed collision avoidance,“ *IEEE Transactions on Intelligent Transportation Systems*, 2018.

- [5] J. Ploeg, B. T. M. Scheepers, E. van Nunen, N. van de Wouw und H. Nijmeijer, „Design and experimental evaluation of cooperative adaptive cruise control,“ *IEEE Conference on Intelligent Transportation Systems*, pp. 260-265, 2011.
- [6] J. Rios-Torres und A. A. Malikopoulos, „A survey on the coordination of connected and automated vehicles at intersections and merging at highway on-ramps,“ *IEEE Transactions on Intelligent Transportation Systems*, pp. 1835-1842, 2017.
- [7] A. Schwab und J. Lunze, „Cooperative vehicle merging with guaranteed collision avoidance,“ *IFAC Workshop on Control of Transportation Systems (accepted)*, 2019.
- [8] K. Schenk und J. Lunze, „Tracking control of networked and interconnected systems,“ *IFAC Workshop on Distributed Estimation and Control in Networked Systems*, pp. 40-45, 2018.
- [9] I. M. Horowitz, *Synthesis of Feedback Systems*, Academic Press, 1963.

# Simulation von interagierenden Verkehrsteilnehmern in einer urbanen Testumgebung mittels einer skalierten Fahrzeugplattform

## Simulation of Interacting Road Users in an Urban Test Environment Using a Scaled Experimental Vehicle

M.Sc. **Christoph Hebisch**, Dr.-Ing. **Frank-Josef Heßeler**,  
Univ.-Prof. Dr.-Ing. **Dirk Abel**,  
Institut für Regelungstechnik, RWTH Aachen

### Kurzfassung

Der wachsende Stellenwert von automatisierten Fahrfunktionen geht mit einer steigenden Nachfrage nach neuartigen Validierungskonzepten einher. Bei der Entwicklung von Autonomiefunktionen stellt der innerstädtische Raum aufgrund der großen Vielfalt an auftretenden Verkehrsszenarien mit unterschiedlichen interagierenden Verkehrsteilnehmern und Straßen- topologien eine besondere Herausforderung dar, weshalb es hierfür neuartiger Werkzeuge und Validierungskonzepte bedarf.

In diesem Beitrag werden Konzepte zur Entwicklung und Validierung automatisierter Fahrfunktionen im innerstädtischen Bereich vorgestellt, bei denen die am Institut für Regelungstechnik der RWTH Aachen entwickelte, skalierte Fahrzeugplattform IRT-Buggy zur Simulation von Verkehrsteilnehmern eingesetzt wird. Mit den entwickelten Werkzeugen lassen sich neben komplexen Verkehrsszenarien mit mehreren Verkehrsteilnehmern auch Szenarien zur Validierung von Notbremsassistsystemen (Autonomous Emergency Braking, AEB) darstellen, indem der IRT-Buggy als Antriebssystem für Fußgänger-Dummies eingesetzt wird.

### Abstract

The growing importance of automated driving functions is accompanied by an increasing demand for novel validation concepts. In the development of Advanced Driver Assistance Systems (ADAS), the urban space poses a particular challenge due to the large variety of traffic scenarios with different interacting road users and road topologies, which is why novel tools and validation concepts are required.

This paper presents concepts for the development and validation of automated driving functions in inner-city areas using the scaled vehicle platform IRT-Buggy for the simulation of road users. With the developed tools, complex traffic scenarios with several road users as well as

scenarios for the validation of Autonomous Emergency Braking (AEB) systems can be simulated by utilizing the IRT-Buggy as a propulsion system for pedestrian dummies.

## 1. Einleitung

Moderne Sensorsysteme und Algorithmen erlauben bereits heute den teilautonomen Betrieb von Serienfahrzeugen auf Autobahnen. Demgegenüber stellt die innerstädtische Anwendung von (teil-)autonomen Fahrfunktionen insbesondere aufgrund der hohen Komplexität von möglichen Verkehrsszenarien mit unterschiedlichsten Verkehrsteilnehmern und bislang ungeklärter ethischer Aspekte eine bedeutend größere Hürde dar [1], [2].



Bild 1: Luftaufnahme der CERMcity auf dem Gelände des Aldenhoven Testing Centers.

Der Entwicklungsprozess für automatisierte Fahrfunktionen im innerstädtischen Bereich bedarf geeigneter Testumgebungen und Infrastruktur zur realitätsnahen Abbildung aller relevanter Verkehrssituationen. Die im Rahmen des vom Bundesministerium für Bildung und Forschung (BMBF) geförderten Forschungsprojekts CERMcity (Center for European Research on Mobility) entstandene innerstädtische Testumgebung auf dem Gelände des Aldenhoven Testing Centers (ATC), der Automobilteststrecke der RWTH Aachen, stellt ein solches Testfeld dar und enthält umfangreiche netzwerktechnische und straßenbauliche Infrastruktur für eine Vielzahl von Verkehrsszenarien (Bild 1).

Neben der Infrastruktur werden für die realitätsnahe und reproduzierbare Abbildung von innerstädtischen Verkehrssituationen auch Werkzeuge zur Simulation von Verkehrsteilnehmern benötigt. Die im folgenden Abschnitt beschriebene skalierte Fahrzeugplattform IRT-Buggy bietet hierfür vielfältige Anwendungsmöglichkeiten.

## 2. Der IRT-Buggy als Simulationsplattform für Verkehrsteilnehmer

Die in Bild 2.a) dargestellte skalierte Fahrzeugplattform IRT-Buggy ist ein am Institut für Regelungstechnik der RWTH Aachen entwickelter Versuchsträger, welcher modular erweiterbar ist und somit für eine Vielzahl an Anwendungen eingesetzt werden kann [3], [4], [5]. Die auf dem IRT-Buggy integrierte Sensorik und die verfügbaren Kommunikationsschnittstellen beinhalten unter anderem einen RTK-fähigen GNSS-Empfänger zur hochgenauen Positionsbestimmung, eine inertiale Messeinheit und LiDAR-Sensoren zur präzisen Umfelderfassung sowie XBee-Funkmodule und WLAN-AC, welche sowohl die Simulation von kooperativen Verkehrsszenarien mit mehreren IRT-Buggys, als auch die Berücksichtigung der auf dem CERMcity-Gelände zur Verfügung stehenden Infrastrukturinformationen, wie z.B. Ampelsignale, ermöglichen.

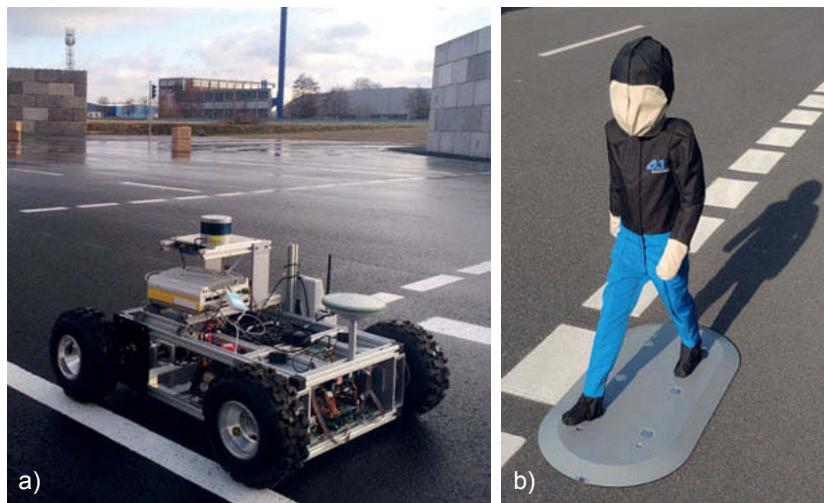


Bild 2: Der IRT-Buggy auf dem Gelände der CERMcity (a) und ein VRU-Dummy mit schleifbarer Bodenplatte (b).

Die Regelung der Dynamik des IRT-Buggys erfolgt hierarchisch über eine Basisregelung, welche als Schnittstelle zu den Sensoren und Aktuatoren agiert, und eine High-Level-Regelung, welche der Basisregelung eine Soll-Geschwindigkeit und einen Soll-Lenkinkel vorgibt und auf einem separaten Embedded-PC ausgeführt wird. Bestandteil der Basisregelung ist ein integrierter Hardware-in-the-Loop (HiL) Simulator [6], welcher ein Modell der Dynamik des IRT-Buggys und seiner Sensoren enthält und über welchen die Basisregelung realistische Sensorwerte erzeugen und an die High-Level-Regelung senden kann, wodurch die Anwendbarkeit von neuen Algorithmen oder Hardware-Systemen bereits im Labor auf dem Zielsystem validiert werden kann. Die Kommunikation zwischen Basisregelung und der High-Level-Regelung erfolgt über ein CAN-Interface.

Das vorhandene Software-Framework des IRT-Buggy enthält eine navigations- und kartenbasierte Sollpfadregelung (Virtual Track) [7], mit welcher die Fahrzeuge autonom frei definierbare Pfade, vergleichbar mit einer „virtuellen Schiene“, befahren können, welche über eine digitale georeferenzierte Karte im OSM-Dateiformat vorgegeben werden können.

Die Virtual-Track-Funktionalität ermöglicht die Abbildung kooperativer Verkehrsszenarien mit mehreren IRT-Buggys, indem die von den individuellen Fahrzeugen geplanten Pfade und Manöver über eine Funkschnittstelle an die anderen Fahrzeuge gesendet werden. Die somit verfügbaren Informationen können bei den anderen Fahrzeugen bei der Pfadplanung berücksichtigt werden, sodass auch längere Testszenarien, welche eine präzise Synchronisierung der verschiedenen Verkehrsteilnehmer voraussetzen, abgebildet werden können. Durch Integritätsprüfung der V2V-Kommunikation und die Verwendung von LiDAR-Sensoren zur Kollisionserkennung kann der sichere Betrieb von Testszenarien mit mehreren IRT-Buggys sichergestellt werden.

### 3. VRU-Antriebssystem

Ein Anwendungsszenario des IRT-Buggys im Kontext der Entwicklung automatisierter Fahrfunktionen ist der Einsatz als Antriebssystem für Vulnerable Road User (VRU) Dummies, welche zur Validierung von Notbremsassistenzsysteme (Autonomous Emergency Braking, AEB) eingesetzt werden. Hierbei wird ein auf einer Standplattform fixierter Fußgänger-Dummy (Euro NCAP Pedestrian Target, EPT) über einen Zugriemen mit einer Länge von fünf Metern vom IRT-Buggy gezogen, wodurch sich automatisiert und reproduzierbar Gefahrensituationen mit Fußgängern im innerstädtischen Raum simulieren lassen.

Gegenüber stationären riemengetriebenen Antriebssystemen bietet der IRT-Buggy eine deutlich schnellere und flexiblere Rekonfiguration des Testszenarios und ermöglicht komplexere Trajektorien des VRU-Dummies. Die im Rahmen dieses Beitrags eingesetzten VRU-Dummies

vom Typ 4activePS replizieren die Eigenschaften von typischen Fußgängern für Kamera-, Radar- und LiDAR-Systeme und können beschädigungsfrei mit Realfahrzeugen kollidieren. Ein typisches Testszenario zur Validierung von Notbremsassistsystemen, welches dem vom Euro NCAP definierten Testprotokoll CPNC-50 (Car-to-Pedestrian Nearside Child 50%) [8] entspricht, ist in Bild 3 dargestellt. Hierbei wird ein VRU-Dummy, der sich zu Beginn des Szenarios hinter einem geparkten Fahrzeug befindet, mit einer Geschwindigkeit von 5 km/h senkrecht kreuzend vor das sich nähernde Testfahrzeug (Vehicle Under Test, VUT) gezogen, sodass es ohne Bremseingriff seitens des Testfahrzeugs zum Zeitpunkt  $T_{\text{impact}}$  an der Position  $L = (X_L, Y_L)$  zur Kollision zwischen dem VRU-Dummy und dem Mittelpunkt der Fahrzeugfront kommt. Die Position der Hüfte des Dummies dient als Referenzpunkt (H) des VRU-Dummies und befindet sich zu Beginn des Testszenarios vier Meter (E) entfernt von der Längsachse des Testfahrzeugs. Nach einer zurückgelegten Strecke von einem Meter (G) muss der Dummy eine stationäre Geschwindigkeit von  $V_{\text{EPT}} = 5 \text{ km/h} \approx 1,389 \text{ m/s}$  erreichen und diese bis zum Zeitpunkt  $T_{\text{impact}}$  halten. Der Zeitpunkt, zu dem der VRU-Dummy die Strecke G zurückgelegt haben soll, wird als  $T_{\text{steady}}$  bezeichnet. Die erlaubte Abweichung von der Soll-Geschwindigkeit zwischen  $T_{\text{steady}}$  und  $T_{\text{impact}}$  beträgt  $\pm 0,2 \text{ km/h} \approx 0,056 \text{ m/s}$ . Das Testfahrzeug hat während der Testdurchläufe jeweils eine konstante Geschwindigkeit zwischen  $V_{\text{VUT}} = 20 \text{ km/h}$  und  $60 \text{ km/h}$ .

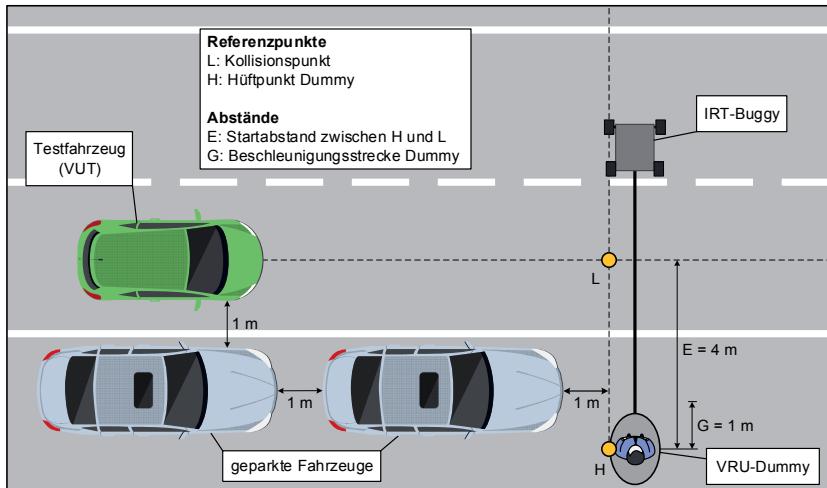


Bild 3: Schematischer Versuchsaufbau zur Validierung von AEB-Systemen.

Zur Umsetzung des betrachteten Szenarios CPNC-50 mit dem IRT-Buggy als Antriebssystem wurde die in Bild 4 dargestellte Systemstruktur entwickelt. Damit eine exakte örtliche und zeitliche Synchronisierung des EPT erfolgen kann, sendet das Testfahrzeug über eine Drahtlos-schnittstelle seine aktuelle Pose ( $X_{VUT}$ ,  $Y_{VUT}$ ,  $\Psi_{VUT}$ ) in lokalen kartesischen Koordinaten und seine Geschwindigkeit  $V_{VUT}$  zum Antriebs-Buggy. Aus der Position des Testfahrzeugs lässt sich unmittelbar der Abstand  $D_{VUT}$  des Testfahrzeugs zum Kollisionspunkt L bestimmen. Durch Kenntnis von  $D_{VUT}$  und  $V_{VUT}$  ergibt sich die verbleibende Zeit bis zum Erreichen des Kollisionszeitpunktes  $T_{impact}$  zu  $TTC = D_{VUT} / V_{VUT}$  (Time To Collision).

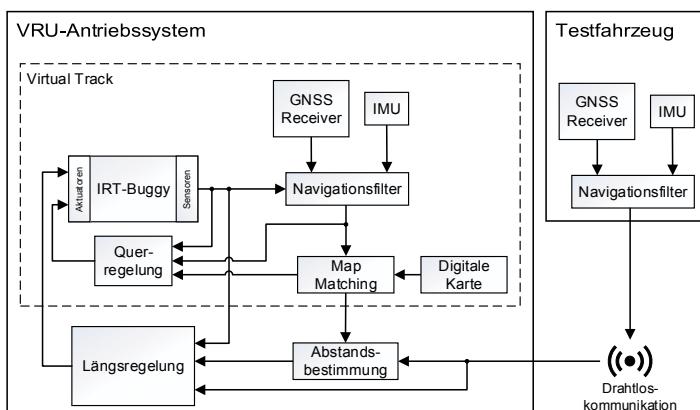


Bild 4: Systemstruktur des automatisierten VRU-Antriebssystems.

Um eine präzise Positionierung des VRU-Dummys longitudinaler und lateraler Richtung zu gewährleisten, wurde das Virtual-Track-Framework des IRT-Buggys zu der in Bild 4 gezeigten Systemstruktur erweitert. Damit der VRU-Dummy zeitgleich mit dem VUT den Kollisionspunkt erreicht, muss eine Geschwindigkeitstrajektorie für den Antriebs-Buggy generiert werden, welche die Spezifikationen des Testprotokolls erfüllt. Hierfür kann beispielsweise eine Geschwindigkeitstrajektorie mit konstantem oder stückweise linearem Verlauf der Beschleunigung gewählt werden, woraus eine rampenförmige bzw. S-förmige Geschwindigkeitstrajektorie resultiert, welche von der Basisregelung des Buggys eingeregelt wird. Falls der VRU-Dummy den Kollisionspunkt zeitlich versetzt bezüglich des Testfahrzeugs erreichen soll, kann ein entsprechender Offset  $\Delta T_{impact}$  der Längsregelung als Parameter vorgegeben werden, durch welchen die Soll-Geschwindigkeitstrajektorie entsprechend zeitlich verschoben wird.

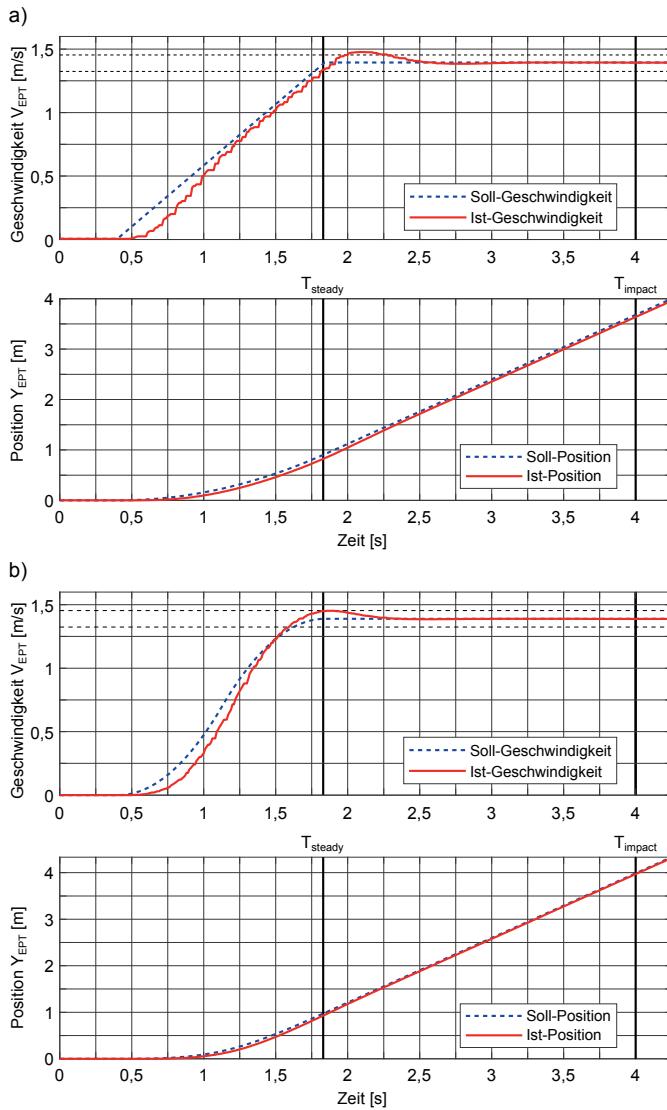


Bild 5: Experimentelle Ergebnisse der HiL-Simulation für das Szenario CPNC-50 mit rampenförmigem (a) und S-förmigem Sollgeschwindigkeitsverlauf (b).

#### 4. Ergebnisse

Zur Validierung des in Abschnitt 3 vorgestellten Systems zur Nutzung des IRT-Buggys als Antriebssystem für VRU-Dummys wurde mittels des integrierten HiL-Simulators das Testszenario CPNC-50 mit zwei unterschiedlichen Soll-Geschwindigkeitsverläufen simuliert. Das Testfahrzeug wurde hierbei durch einen zweiten Buggy simuliert, welcher sich dem Kollisionspunkt gemäß des Testprotokolls mit einer konstanten Geschwindigkeit von 20 km/h nähert. Die Übertragung der Pose und Geschwindigkeit des VUT zum Antriebs-Buggy erfolgte über die XBee-Funkschnittstelle. Da in dem untersuchten Szenario lediglich ein geradliniger Pfad vorgegeben wird, wird im Folgenden nur die longitudinale Position  $Y_{EPT}$  des VRU-Dummys betrachtet. Die simulierten Verläufe der Geschwindigkeit und der longitudinalen Position  $Y_{EPT}$  des EPT für einen rampenförmigen und einen S-förmigen Soll-Geschwindigkeitsverlauf sind in Bild 5 dargestellt.

Tabelle 1: Regelabweichungen der Geschwindigkeit  $V_{EPT}$  und longitudinalen Position  $Y_{EPT}$  des EPT mit rampenförmigem (a) und S-förmigem Soll-Geschwindigkeitsverlauf (b) zu den Zeitpunkten  $T_{steady}$  und  $T_{impact}$  sowie die betragsmäßig maximale Regelabweichung im betrachteten Zeitintervall.

a) Rampe	$T_{steady}$	$T_{impact}$	Max.
$V_{EPT,soll} - V_{EPT,ist}$ [m/s]	0,055	0,001	-0,083
$Y_{EPT,soll} - Y_{EPT,ist}$ [m]	0,086	0,046	0,087

b) S-Kurve	$T_{steady}$	$T_{impact}$	Max.
$V_{EPT,soll} - V_{EPT,ist}$ [m/s]	-0,050	0,001	-0,053
$Y_{EPT,soll} - Y_{EPT,ist}$ [m]	0,074	0,047	0,074

Bei einem rampenförmigen Soll-Geschwindigkeitsverlauf muss der Antriebs-Buggy zum Erreichen der vom Testprotokoll geforderte Geschwindigkeitsänderung von  $V_{EPT} = 0$  m/s auf  $V_{EPT} = 1,389$  m/s innerhalb von  $T_{ACC} = 1,44$  s mit konstant  $A_{EPT} = 1,93$  m/s<sup>2</sup> beschleunigt werden, um die Beschleunigungsstrecke  $E = 1$  m zurückzulegen (Bild 5.a)). Die geforderte Beschleunigung liegt dabei unterhalb der Maximalbeschleunigung des IRT-Buggys von knapp 3 m/s<sup>2</sup> bei geringen Geschwindigkeiten [3]. Aufgrund der Kommunikationslatenz der CAN-Schnittstelle und des verzögerten Führungsverhaltens der Drehzahlregelung wird das Toleranzintervall der Soll-Geschwindigkeit bis zum Zeitpunkt  $T_{steady}$  nur knapp erreicht und die Ist-Geschwindigkeit liegt aufgrund des Überschwingens zwischen  $T_{steady}$  und  $T_{impact}$  nicht vollständig

innerhalb des vorgegebenen Toleranzintervalls. Zum Kollisionszeitpunkt liegt nur noch eine geringe Abweichung von der Soll-Geschwindigkeit und Soll-Position vor.

Bei dem in Bild 5.b) gezeigten S-förmigen Verlauf der Soll-Geschwindigkeit beträgt die Abweichung maximal 0,053 m/s, was innerhalb des Toleranzintervalls liegt. Die Positionsabweichung ist insgesamt geringer als bei der rampenförmigen Soll-Geschwindigkeitstrajektorie.

## 5. Zusammenfassung und Ausblick

In diesem Beitrag wurden Einsatzmöglichkeiten der skalierten Fahrzeugplattform IRT-Buggy im Kontext der Entwicklung und Validierung von automatisierten Fahrfunktionen in innerstädtischen Szenarien und die Anwendungsmöglichkeit als Antriebssystem für VRU-Dummies vorgestellt. Hierzu wurde ein bestehendes Querregelungs-Framework um Funktionalitäten zur präzisen zeitlichen und örtlichen Synchronisierung mit einem Testfahrzeug erweitert, wodurch sich automatisiert und reproduzierbar beliebig konfigurierbare Szenarien abbilden lassen. Zur Demonstration der Anwendbarkeit der entwickelten Funktionalitäten wurde ein vom Euro NCAP definiertes Testszenario zur Validierung von Notbremsassistentensystemen betrachtet und Experimente mit dem integrierten HiL-Simulator des IRT-Buggys für verschiedene Soll-Geschwindigkeitsverläufe durchgeführt. Die simulativen Experimente kommen zu dem Ergebnis, dass der IRT-Buggy bei Wahl einer geeigneten Geschwindigkeitstrajektorie in der Lage ist, die im Testprotokoll definierten Toleranzen einzuhalten. Zur Verifikation der Simulationsergebnisse werden zukünftig weitere Experimente mit der realen Hardware durchgeführt, bei denen auch weitere Testszenarien näher untersucht werden. Eine bislang nicht betrachtete Größe ist die laterale Abweichung des VRU-Dummies vom Sollpfad. Da eine exakte Lokalisierung nur für den Buggy selber möglich ist, könnte mittels einer auf dem Buggy angebrachten Kamera oder eines LiDAR-Sensors die Relativposition des VRU-Dummies exakt bestimmt werden. Dies würde neben der präziseren Positionierung in lateraler Richtung auch die Möglichkeit zum Fahren komplexerer Positionstrajektorien des VRU-Dummies erlauben.

## 6. Danksagung

Dieser Beitrag entstand im Rahmen des durch das Bundesministerium für Bildung und Forschung (BMBF) geförderten Projekts CERMcity.

## Literatur

- [1] Maurer, M.: Autonomes Fahren: Technische, rechtliche und gesellschaftliche Aspekte. Springer-Verlag 2015
- [2] Koopman, P., Wagner, M.: Challenges in autonomous vehicle testing and validation. SAE International Journal of Transportation Safety 4(1) (2016) S. 15–24
- [3] Reiter, M.: Environment and Tools for the Development of Navigation- and Map-based Driver Assistance and Vehicle Guidance Systems. RWTH Aachen Diss. 2017
- [4] Reiter, M., Alrifae, B., Abel, D.: Model scale experimental vehicle as test platform for autonomous driving applications. FISITA 2014 World Automotive Congress (2014)
- [5] Reiter, M., Abel, D., Rofalski, S., Moormann, D.: GNSS-, Communication- and Map-Based Control System for Initiation of a Heterogeneous Rendezvous Maneuver. IFAC-PapersOnLine 49(3) (2016) S. 171–177
- [6] Reiter, M., Wehr, M., Abel, D.: Built-in HiL simulator: A concept for faster prototyping of navigation-and communication-based control systems. IEEE International Conference on Advanced Intelligent Mechatronics (AIM) (2016) S. 1363–1369
- [7] Reiter, M., Abel, D.: Two and a half carrots - a versatile and intuitive optimisation-based path-following approach for road vehicles. IEEE Mediterranean Conference on Control and Automation (MED) 23 (2015) S. 364–370
- [8] Euro NCAP AEB VRU Test Protocol v2.0.4 (2019)

# Polytopic LPV Controller Design to Control the Boost Manifold Pressure in an Internal Combustion Engine

M.Sc. Nishanth Althar Udupa, M.Sc. Erik Schulz,  
Dipl.-Ing. Matthias Schultalbers,  
IAV Automotive Engineering GmbH, Gifhorn

## Abstract

Controlling the boost manifold pressure is an essential entity in an internal combustion engine. In production vehicles, the control architecture and design has been evolved since decades to accomplish the task of attaining sufficient boost manifold pressure. One very recent control strategy [1], the so-called classical gain-scheduling, involves smartly tuned local linear time-invariant (LTI) controllers designed at several operating points and further interpolated about the entire operating range. A more modern and appropriate control technique for such a nonlinear system is, for example, the linear parameter varying (LPV) approach. This research work throws light on a polytopic LPV controller architecture which has the potential to replace the local LTI controllers with a single controller about the entire operating range. The designed LPV controller assures stability and performance throughout the operating range and can be easily implemented in the engine control unit (ECU).

## 1. Introduction

To increase the fuel efficiency the modern cars are equipped with turbocharged internal combustion (IC) engines. Since decades researchers have come up with different methods to control the boost manifold pressure with respect to different operating points which are dependent on relative air charge in the cylinder and engine torque [3]. The boost manifold pressure is measured in between the throttle valve and the intake manifold of the engine cylinders. Entities in an IC engine, such as the percentage of throttle valve opening, the percentage of air intake etc. are highly dependent on the operating point. As these entities show nonlinear and time-varying behaviour, modelling the relationship between the inputs, outputs and the states using first principles could be a cumbersome task. Due to this reason, the control of boost manifold pressure at different operating points is a challenging task.

The nonlinear and time-varying systems pose a great challenge to the classical control techniques with LTI methods. These challenges could be easily dealt with by using LPV systems which provide a better framework for modelling and controlling time-varying and nonlinear systems. In the past two decades the principles of LPV framework has taken over a vast range of applications e.g. in the automotive industry [4], aerospace [5], and robotics [6]. A survey [2] provides an overview of different application which employs LPV techniques. In

this current research, a technique to control the boost manifold pressure using the LPV framework is proposed.

A discrete-time LPV model of the boost manifold pressure system is identified in [7] on the basis of measured data recorded on an engine test bench is borrowed in this research. It is transformed into a polytopic state-space [8] model, where the model's system and input matrices have a functional dependency on the three affine scheduling parameters. Local stability analysis is conducted at different operating points. Since the scheduling parameters are bounded, the polytopic parameter space is considered as a three-dimensional hyperbox which results in over bounding of the parameter space. This conservatism is significantly reduced by selecting the hyperbox using rigid transformation [9]. The control design conditions in [10] are used to obtain an optimal controller with respect to the  $H_{\infty}$  norm [11]. Finally, the designed LPV controller is implemented on the engine calibration unit and a comparison with the existing series controller is carried out and the results are discussed.

This research work totally consists of 5 sections. The second section describes the polytopic single input single output (SISO) LPV system and the scheduling parameters. It also throws light on the local open loop stability of the plant. The third section discusses the controller design and implementation of the designed controller in the test bench. The fourth section concludes the research work and also opens the window for any future scope.

## 2. Boost Pressure System

In this research, the system to be controlled is the boost pressure system in a gasoline engine. The schematic representation is shown in Fig. 1. The air flow direction is denoted by the dashed direction arrow marks. The air is filtered in the air filter before being compressed in the compressor. The compression process generates heat which is then removed in the air cooler. As the heat is removed the density of the air increases which intern increases the concentration of Oxygen per unit volume. The rate of flow of the compressed air to the inlet manifold is controlled by the throttle valve. In this research, the throttle valve is considered to be fully open. The measured amount of compressed air is distributed in the cylinders through the inlet valve. After the combustion process, the exhaust gases flow through the exhaust valve into the exhaust manifold. A part of the exhaust gas enters the turbine and follows the expansion process. The other part passes through the waste gate and does not undergo expansion. A valve at the waste gate controls the mass flow rate of the exhaust gases. Finally, the exhaust gases are released to the atmosphere via catalyzer. The entity named boost manifold pressure is measured between the compressor and the air cooler. In this current research, the boost manifold pressure is controlled with the help of the valve opening of the waste gate. Therefore,

the input to the system is the waste gate valve opening and the output is the boost manifold pressure.

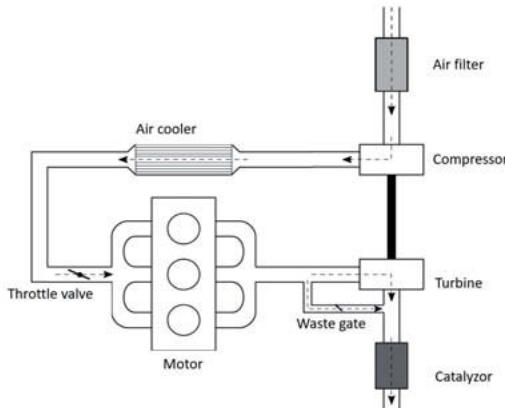


Fig. 1: Schematic representation of the boost pressure system [6]

## 2.1 Polytopic LPV Representation of the Boost Pressure System

The boost pressure system is considered to be a nonlinear system and can be represented as a discrete-time parameter dependent system as shown in the following

$$\begin{aligned} x_{k+1} &= f(\rho_k, x_k, u_k) \\ y_k &= h(\rho_k, x_k, u_k), \end{aligned} \quad (1)$$

where  $x_k$  is the state of the system at the corresponding time instance  $k$ ,  $u_k$  is the reference waste gate position and  $y_k$  is the boost manifold pressure. The system's dependency on time is expressed via time-varying scheduling parameters  $\rho_{k,i}$ ,  $i = 1, \dots, n_\rho$  which are collected in a parameter vector  $\rho_k$  which is associated with a compact set  $P_\rho$  with an assumption such that  $\rho_k \in P_\rho \subset \mathbb{R}^{n_\rho}$ . For this system, the scheduling parameter is  $\rho_k = [n_k \ r l_k]^T$ , where  $n_k$  is the engine speed and  $r l_k$  is the relative air charge.

The above parameter dependent discrete-time system can be expressed as an LPV system as shown in the following

$$\begin{aligned} x_{k+1} &= A(\theta_k)x_k + B(\theta_k)u_k \\ y_k &= C(\theta_k)x_k + D(\theta_k)u_k. \end{aligned} \quad (2)$$

A further assumption is done such that  $\theta_k \in P_\theta \ \forall k \geq 0$  for a given compact set  $P_\theta \subset \mathbb{R}^{n_\theta}$ . Such systems are called polytopic systems, if they satisfy the following conditions:

- 1) The set  $P_\theta$  can be expressed as a convex hull. Meaning,

$$P_\theta = \text{Co}\{\theta_{v,1}, \theta_{v,2}, \dots, \theta_{v,s}\},$$

where  $\theta_{v,i} \in \mathbb{R}^{n_\theta}$  are the vertices of the polytope and  $s$  is the number of vertices. This also implies

$$P_\theta = \{\theta_k \in \mathbb{R}^{n_\theta} \mid \theta_k = \sum_{i=1}^s \alpha_i \theta_{v,i}, \sum_{i=1}^s \alpha_i = 1, \alpha_i \geq 0, i = 1, \dots, s\},$$

where the coefficients  $\alpha_i$  are referred to as convex coordinates.

- 2) The system described in (2) has an affine dependency on the parameter vector  $\theta_k$ . In this case, the set of admissible LTI systems that is generated when  $\theta_k$  in (2) ranges over the polytope  $P_\theta$  is itself a polytope, i.e. it can be represented by

$$\begin{bmatrix} A(\theta_k) & B(\theta_k) \\ C(\theta_k) & D(\theta_k) \end{bmatrix} = \text{Co} \left\{ \begin{bmatrix} A_i & B_i \\ C_i & D_i \end{bmatrix}, i = 1, \dots, s \right\},$$

where  $(A_i, B_i, C_i, D_i) = (A(\theta_{v,i}), B(\theta_{v,i}), C(\theta_{v,i}), D(\theta_{v,i}))$ ,  $i = 1, \dots, s$  are the vertex plants.

In this current research, the scheduling signal  $\theta_k = [rl_k \ rl_k^2 \ n_k]^T$  as a result, the scheduling parameter space is a three-dimensional rectangle which is also called a hyperbox. The axes of the hyperbox are formed by the scheduling signals whose bounds are determined by the range of the scheduling signals used in the identification process. It is important to note that the above assumptions made introduces significant conservatism in this approach. However, a trade-off between simplicity and conservatism is to be made according to the implementation techniques.

## 2.2 Stability Analysis of the LPV System

For the purpose of better description and to present several signals in one plot, the input, output and the scheduling signals are normalized. The maximum and the offset values are described in Table 1. It is to be noted that the air inside the cylinder is considered to be 100 percent charged and the relative air charge is measured with respect to this value. Also, the waste gate is considered to be totally open if the aperture opening is 0.

Entity	Offset	Maximum value	Units
Relative air charge $rl$	90	50.81	%
Engine speed $n$	2200	1800	rpm
Boost manifold pressure $y$	1200	496	mbar
waste gate valve $u$	0	96.57	%

Table 1: Maximum and offset values used for scaling with  $x_{\text{scaled}} = \frac{x - x_{\text{offset}}}{x_{\text{max}}}$

A local stability analysis is performed by defining a grid on the hyperbox. Thus, each grid point represents a frozen LTI system. Then, stability of the LTI model at each grid point is checked. The grid point is marked with a red cross if it is unstable and marked with a green circle if it is stable (see Fig. 3). Since two of the scheduling signals are  $rl$  and  $rl^2$ , they are governed by a parabolic equation for each value of  $n$ . This relation is shown by a blue curve, plotted for the range of  $rl_{\text{scaled}}$ . It must be taken into account that the global stability of the entire system cannot be concluded from the local LTI stability analysis, however controller design is based on the local LTI models is analysed where the LTI models are stable.

In order to find an appropriate parameter space, such that the controller is not designed for “artificial” unstable systems, the hyperbox which is described with a red rectangle in Fig. 3 and obtained after rigid transformation is chosen within which the local LTI systems are stable. However, this section of the hyperbox does not enclose the entire operating range. It can be seen that the operating region with low and high relative air charge are not be enclosed in this hyperbox. The reason for this being during the controller design no solution for the linear matrix inequalities (LMI) is found for the entire parameter space. On the other hand the regions not covered in the hyperbox are occasionally reached and are not of much importance in this current research.

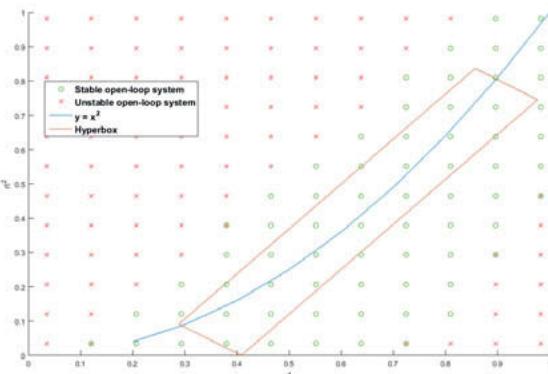


Fig. 3: Local system stability on a grid of the parameter space for the affine scheduling parameters plotted with respect to the  $rl$  and  $rl^2$  axes of the hyperbox

### 3. Boost Manifold Pressure Control using LPV Methods

In this subsection a polytopic LPV controller is designed for the eight corners of the parameter space hyperbox (see Fig. 3). Further, the convex coordinates for this hyperbox are calculated in order to interpolate the designed controllers.

### 3.1 S/KS Mixed Sensitivity Design

For the closed-loop system shown in Fig. 4, design objectives considering reference tracking, disturbance rejection, input constraints, performance and overshoot (also called design constraints) are taken into consideration in this research work. Firstly, the output must track the reference value. Secondly, the controller must reject the output disturbance which occur mainly due to the uncertainties in the model and keep the controlled output at its desired value in the presence of disturbance. Finally, the two criteria must be achieved with respect to a given constraint on the controlled input which itself is the third objective [11].

To accomplish the control objectives,  $H_\infty$  norm optimal control design from LTI theory can be employed, where the design specifications are expressed on the closed-loop system.

It is important to note that for a purpose of simplification  $H_\infty$  norm optimal control design is discussed for LTI systems, but this controller design could be easily extended to the LPV systems. For this purpose, sensitivity and control sensitivity functions are introduced. Consider a discrete-time closed-loop system as shown in Fig. 4 with system  $G(z)$  and controller  $K(z)$ .

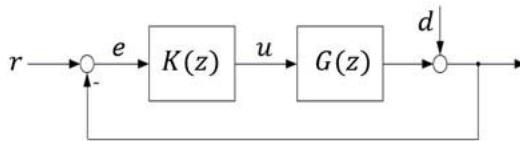


Fig. 4: Closed-loop system

The external inputs are the reference input  $r$  and an output disturbance  $d$ . The controlled output is  $y$  and the input to the system  $G$  is  $u$ . We have  $y = Gu + d$  and substituting  $u = K(r - y)$ , the controlled output becomes

$$y = (I + GK)^{-1} GKr + (I + GK)^{-1} d. \quad (3)$$

Now defining the sensitivity  $S(z) = (I + G(z)K(z))^{-1}$  and the complementary sensitivity  $T(z) = (I + G(z)K(z))^{-1} G(z)K(z)$  we express  $y$  and  $e$  as follows

$$y = Tr + Sd \quad (4)$$

$$e = S(r - d). \quad (5)$$

$S(z)$  is the transfer function from the output disturbance  $d$  to the controlled output  $y$ . Therefore, to achieve good reference tracking and good output disturbance rejection  $S(z)$  has to be minimized. On the other hand,  $u = Ke$  and substituting  $e$  according to (6) we get

$$u = KS(r - d). \quad (6)$$

The term  $KS$  in (7) is defined as control sensitivity. To achieve the design objective with reasonable control effort, the transfer function  $K(z)S(z)$  should also be minimized. This is achieved by imposing a dynamic constraint on the control sensitivity.

The so called  $S/KS$  design is used for addressing reference tracking and output disturbance rejection objectives [10]. Consider a closed-loop system as shown in Fig. 5. The fictitious output signals  $z_S$  and  $z_K$  are generated by weighting functions  $W_S(z)$  and  $W_K(z)$ , respectively. Further, we define weighted sensitivity  $W_S(z)S(z)$  as the transfer function from  $r$  to  $z_S$  and weighted control sensitivity  $W_S(z)K(z)S(z)$  as the transfer function from  $r$  to  $z_K$ .

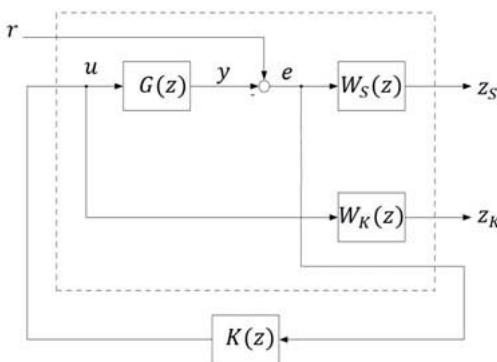


Fig. 5: Closed-loop system with plant, controller and shaping filters

Among the constraints, the first and the second are active in the low frequency region and the third is active in the high frequency region. Usually the low and the high frequency constraints are combined to shape the overall closed-loop system behaviour.

A fictitious output vector for the generalized plant is

$$\begin{bmatrix} z_S \\ z_K \end{bmatrix} = \begin{bmatrix} W_S(z)S(z) \\ W_K(z)K(z)S(z) \end{bmatrix} r. \quad (7)$$

The task is to find the controller  $K(z)$  such that the closed-loop transfer function satisfies

$$\left\| \begin{bmatrix} W_S(z)S(z) \\ W_K(z)S(z)K(z) \end{bmatrix} \right\|_{\infty} < 1. \quad (8)$$

This intern means that the closed-loop system satisfies the constraints which are formulated through the weighting functions  $W_S(z)$  and  $W_K(z)$ .

### 3.2 Choice of Weighting Functions

The task here is to choose and shape the weights for the control problem. It is important to note that the tuning process is first performed considering the weighting functions as a continuous time transfer function. Further, a transformation is done from continuous to discrete time using Tustin approximation. Note that in order to simplify the tuning process, same weights are used for all vertices of the scheduling parameter space instead of using individual weights for the distinct vertices. The weighting function for sensitivity is selected as

$$W_S(s) = \frac{\frac{s}{M_S} + \omega_S}{s + \omega_S A_S} \quad (9)$$

where  $s$  is the Laplace variable,  $A_S$  is the bound on the closed-loop sensitivity at the low frequency region and  $M_S$  is the bound on the high frequency region. The value of  $\omega_S$  determines the bandwidth of the system. A small value is chosen for parameter  $A_S$  to enforce integral action in the low frequency region. To reduce the peak overshoot a small value of  $M_S$  is selected. The bandwidth  $\omega_S$  is chosen on demand.

The weight for the control sensitivity is chosen as

$$W_K(s) = \frac{s + \frac{\omega_K}{M_K}}{A_K s + \omega_K} \quad (10)$$

where  $A_K$  is the bound on the control sensitivity at high frequencies,  $M_K$  the bound at low frequencies and  $\omega_K$  the control bandwidth. With  $M_K$  the amplification of the control signal in the reference tracking frequency range is limited while  $A_K$  is a limit for the measurement noise frequency range [11].

The values chosen as weights for the shaping filters are described in Table 2.

Table 2: Values used for shaping the weighting functions

Weighting functions	$M_S, M_K$	$A_S, A_K$	$\omega_S, \omega_K$
$W_S(s)$	8.5 dB	-65.8 dB	0.8 rad/s
$W_K(s)$	16.5 dB	-83.3 dB	66.7 rad/s

The bode Magnitude plots of the inverse shaping filters are shown in Fig. 6. The eight blue curves represent the sensitivity and the control sensitivity of the eight transfer functions at the vertices of the parameter space hyperbox. These are bounded by the shaping filters which are

represented with a red line. As there is a positive slope of 20 dB/decade in the low frequency region of  $W_S$ , the closed-loop system shows an integral action in the low frequency region. Further, the inverse of the shaping filter  $W_K$  should show a low-pass behaviour to reject high frequencies from the control signal which results in low noise responsiveness, lower actuator fatigue, etc.

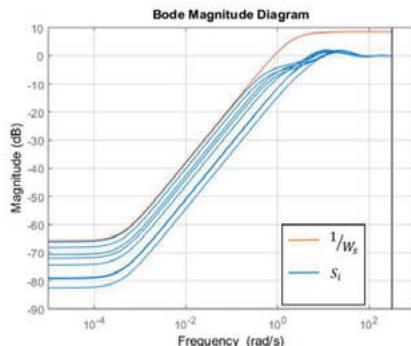


Fig. 6a: Bode magnitude plot of the eight sensitivity functions  $S_i$  which are bounded by the inverse shaping filter  $1/W_S$

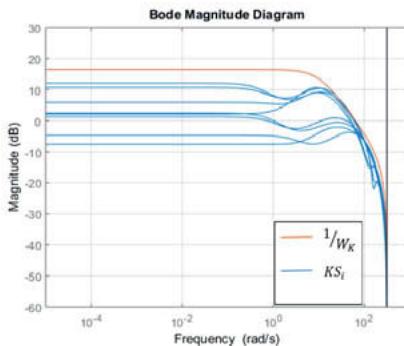


Fig. 6b: Bode magnitude plot of the eight control sensitivity functions  $KS_i$  which are bounded by the inverse shaping filter  $1/W_K$

### 3.3 Implementation on the ECU

The implementation of the controller which is designed in the previous subsection is discussed here. Firstly, the control error  $e$  and the scheduling parameters  $\rho = [rl \ n]^T$  are normalized (see Table 1) and the affine scheduling vector  $\theta = [rl \ rl^2 \ n]^T$  is generated. It is to be noted that the time instance  $k$  is not exclusively mentioned and by default the signals are considered to be in discrete-time domain. Further with the aid of rigid transformations, the corresponding vector with convex coordinates  $\alpha$  is calculated for  $\theta$  at every time instance  $k$ . Since the parameter space is a hyperbox, the individual affine scheduling parameter are assumed to be orthogonal, the calculation of the convex coordinates simplifies to the product of vicinities to the vertex (minimum/maximum) in each dimension. For example, for a specified dimension, a vicinity of one indicates at the vertex and a vicinity of zero at the other vertex of this dimension. These convex coordinates are used for interpolation of the eight vertex controllers which are represented in the form of  $A_K$ ,  $B_K$ ,  $C_K$ , and  $D_K$  matrices as shown in Fig. 7. These matrices are stacked three-dimensional matrices with each layer representing one vertex. At the end, the

output of the controller which basically happens to be the input of the plant is scaled back to its original value and then fed into the plant i.e. the reference for the actuator of the engine on the test bench.

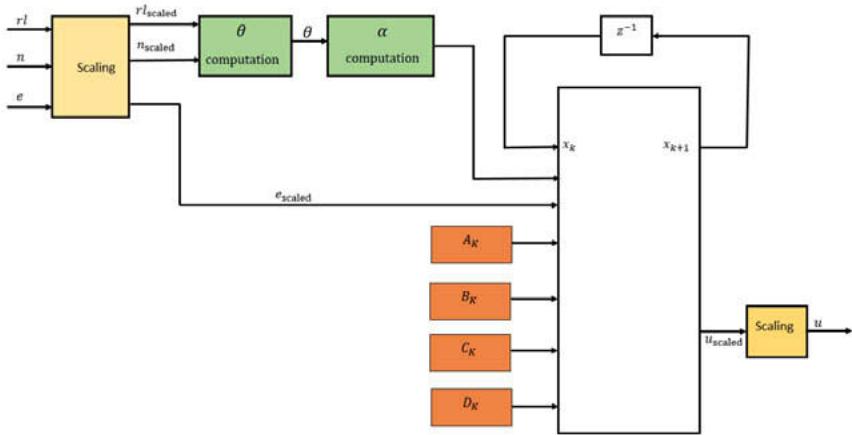


Fig. 7: Description of the scheduling signals and the LPV controller

### 3.4 Measurements on the Test bench

In this subsection, the controller is implemented in the test bench and a comparison is done between the existing controller and the designed LPV controller. As already mentioned, the controller is designed for the plant which has been derived from the measurement values from the test bench. The controller design and tuning process is conducted in Matlab and further the controller implemented in the ECU (see Section 3.3). A comparison is done on the test bench between the LPV controller and the existing controller which is in series production and currently in use. For a purpose of better understanding of the comparison, a fixed value of engine speed is chosen and the relative air charge is varied such that it captures the entire operating range (see Fig. 8a). It could be clearly seen that the LPV controller performs better than the existing controller (see Fig. 8b). The settling time and the rise time of the LPV controller are less compared to the existing controller. On the other hand the boost manifold pressure controlled using the LPV controller shows higher overshoot compared to the existing controller. This is mainly due to the overshoot in the relative air charge. Since the relative air charge and the boost manifold pressure show high dependency on each other, an overshoot is seen in boost manifold pressure due to an overshoot in the relative air charge.

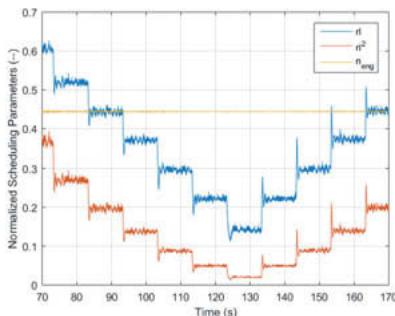


Fig. 8a: Variation of  $r/l$  for a constant  $n$   
(Normalized scheduling signals)

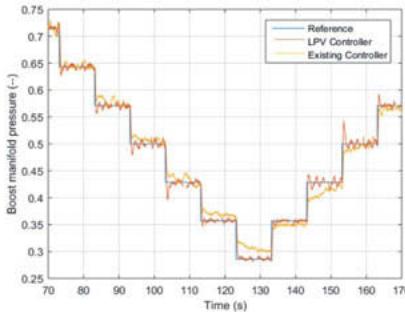


Fig. 8b: Comparison between the LPV and  
the existing controller

#### 4. Conclusion

This work encourages the application of the LPV approach for the control of the boost manifold pressure in internal combustion engines and gives a proof of concept of using data-driven identified LPV models for LPV control design. A discrete-time LPV model identified based on measurements of the IC engine on the test bench is taken for a model based LPV control design, which is optimal in the induced  $L_2$  norm ( $H_\infty$  norm in LTI theory). For the control design, affine scheduling parameter dependence is assumed where overbounding of the parameter space is reduced using rigid transformation. Instead, other techniques like principal component analysis (PCA) can be also used for this. In addition, the parameter space is clipped, because control design is only successful on a reduced scheduling parameter space. Although conservative LPV techniques have been employed for the control design based on a constant Lyapunov function, the results obtained on an engine test bench look promising. The settling time is faster and the steady-state error is smaller compared to the series production controller. However, the boost pressure overshoot is very large at the test bench which is not recognizable in the controller design (peak in the sensitivity). Hence, a redesign of the controller possibly with an improved LPV model is recommendable. Still, the reduction of conservatism is a task for future investigation by using for example a scheduling parameter dependent Lyapunov function or a linear fractional representation, hence to reduce conservatism in the assumed scheduling parameter dependence.

## Reference

- [1] F. Nolteernsting, R. Röthig, T. Oehlschlägel, M. Schultalbers, U. Becker, "Gain-Scheduling-Regelung des Ladedrucks eines Ottomotors auf Basis lokaler linearer strukturierter  $H_{\infty}$ -optimaler Regler", VDI/VDE Fachtagung AUTOREG, July 2019.
- [2] Christian Hoffmann, Herbert Werner, "A Survey of Linear Parameter-Varying Control Applications Validated by Experiments or High-Fidelity Simulations", IEEE Transaction on control system technology, Vol. 23, No. 2, March 2015.
- [3] Jeffrey A. Cook, Jing Sun, Julia H. Buckland, Ilya V. Kolmanovsky, Huei Peng, and Jessy W. Grizzle, "Automotive Powertrain control – A survey", Asian Journal of Control Vol. 8, No. 3, pp. 237-260, September 2006.
- [4] Z. Yu, H. Chen, and P.-y. Woo, "Gain scheduled LPV H-infinity control based on LMI approach for a robotic manipulator", Journal of Robotic Systems, vol. 19, no. 12, pp. 585–593, 2002.
- [5] I. Masubuchi, J. Kato, M. Saeki, and A. Ohara, "Gain-scheduled controller design based on descriptor representation of lpv systems: application to flight vehicle control," in Decision and Control, 2004. CDC. 43rd IEEE Conference on, vol. 1. IEEE, 2004, pp. 815–820.
- [6] R. Zope, J. Mohammadpour, K. Grigoriadis, and M. Franchek, "Robust fueling strategy for an SI engine modelled as an linear parameter varying time-delayed system," in American Control Conference (ACC), 2010. IEEE, 2010, pp. 4634–4639.
- [7] Stefan Kettlitz, "Identifikation lokal linearer Modelle am Beispiel der Ladedruckstrecke", Master thesis in the dept. Mess- und Regelungstechnik, TU-Berlin, 12, October 2018.
- [8] Herbert Werner, "Advanced Topics in Control", Lecture notes, Institute of Control Systems, TU-Hamburg, January 2018.
- [9] Richard M. Murray, Zexiang Li, S. Shankar Sastry, "A Mathematical Introduction to Robotic Manipulation", 1994.
- [10] Pascal Gahinet and Pierre Apkarian, "A Linear Matrix Inequality Approach to  $H_{\infty}$  Control", International Journal of Robust and Nonlinear Control, pp. 421–448, 1994
- [11] Herbert Werner, "Optimal and Robust Control", Lecture notes, Institute of Control Systems, TU-Hamburg, 15/01/2018.
- [12] Erik Schulz, Matthias Schultalbers and Herbert Werner, "Linear Parameter-Varying Control for Air/Fuel Ratio in SI Engines with Parameter Dependent Time Delay", 2016 American Control Conference (ACC), Boston, MA, USA, July 6-8, 2016.

# Gain-Scheduling-Regelung des Ladedrucks eines Ottomotors auf Basis lokal linearer strukturierter $H_{\infty}$ -optimaler Regler

## Systematische robuste Bedatung einer konventionellen Reglerstruktur

**F. Nolteernsting, R. Röthig, T. Oehlschlägel, M. Schultalbers, U. Becker, IAV GmbH, Gifhorn**

### Zusammenfassung

Die Ladedruckregelung ist ein wichtiger Bestandteil der Steuerung moderner Ottomotoren. Die Umsetzung moderner Regelungsverfahren für diese nichtlineare Strecke ist seit Jahren Gegenstand wissenschaftlicher Publikationen. Stand der Technik für den Serienbetrieb ist dagegen eine verhältnismäßig einfache Gain-Scheduling-Struktur basierend auf PID-Reglern und stationärer Vorsteuerung.

Diese Arbeit präsentiert ein serientaugliches Konzept zur Regelung des Ladedrucks und dessen experimentelle Erprobung an einem Prüfstand. Die verwendete Reglerstruktur entspricht weitgehend dem Stand der Technik, wobei die Vorsteuerung signifikant vereinfacht und ein Anti-Windup-Konzept zur systematischen Berücksichtigung von Stellgrößenbeschränkungen ergänzt wurden.

Hervorzuheben ist das verwendete systematische modellbasierte Vorgehen zur  $H_{\infty}$ -optimalen Auslegung der strukturierten Arbeitspunktregler. Der Einsatz  $H_{\infty}$ -optimaler Regler erlaubt die a priori Einbeziehung quantitativer Forderungen an das Verhalten der resultierenden lokalen Regelkreise in den Entwurfsprozess. Das zugrundeliegende Reglerentwurfsverfahren erlaubt lineare Regler beliebiger Struktur. Damit eröffnet sich die Möglichkeit im Einsatz befindliche, von anwendungsorientierten Ingenieuren akzeptierte Reglerstrukturen  $H_{\infty}$ -optimal zu parametrieren. Die Berechnung der Parameter erfolgt zuverlässig durch die Lösung nichtkonvexer und nichtglatter Optimierungsprobleme unter Verwendung veröffentlichter Verfahren.

Die Gewinnung der für den modellbasierten Reglerentwurf erforderlichen mathematischen Systembeschreibungen geschieht durch Identifikation linearer zeitinvarianter Arbeitspunktssysteme.

Die experimentell erzielten Resultate zeigen im Vergleich zu einer konventionell parametrierten Ladedruckregelung deutlich die Leistungsfähigkeit des vorgeschlagenen Regelkonzeptes. Gegenüber dem konventionellen Vorgehen zur Parametrierung auf Basis von Expertenwissen und Fahrversuchen zeichnet sich der aufgezeigte Entwurfsprozess durch das strukturierte, methodische und theoretisch fundierte Vorgehen aus. Der resultierende Entwurfsprozess ist weitestgehend automatisiert und weist einen signifikant reduzierten Ressourcen- und Zeitbedarf auf.

## 1 Einleitung

Ein weit verbreiteter Ansatz zur Effizienzsteigerung bzw.  $CO_2$ -Reduktion bei Otto-Motoren ist das sogenannte Downsizing. Dabei erfolgt eine Verkleinerung des Hubraums und ein aufgeladener Betrieb des Motors, wodurch die für den Ottomotor typischen Drosselverluste reduziert werden können. Die übliche Technik zur Aufladung ist der Abgas-turbolader.

Die Reduktion von Drosselverlusten erfolgt durch einen möglichst breiten Betriebsbereich in dem die Drosselklappe vollständig geöffnet ist. In diesem Betriebsbereich wird in Abhängigkeit von der Fahrpedalstellung ein Solladeldruck berechnet, der über die Ladedruckregelung eingeregelt wird. Die Ladedruckregelung ist folglich in weiten Betriebsbereichen moderner Ottomotoren dafür verantwortlich, dass der über das Fahrpedal geäußerte Fahrerwunsch umgesetzt wird.

### 1.1 Stand der Forschung

Im Folgenden wird der Stand der Forschung im Bereich der Ladedruckregelung sowie des in dieser Arbeit betrachteten Reglersyntheseverfahrens diskutiert.

#### 1.1.1 Aktuelle Arbeiten zur Ladedruckregelung

Im Bereich der Ladedruckregelung gibt es eine erhebliche Diskrepanz zwischen dem Stand der Technik, wie er in aktuellen Serienfahrzeugen eingesetzt wird und Regelungskonzepten die in aktuellen Publikationen thematisiert wer-

den. Als Stand der Technik kann eine Zwei-Freiheitsgrade-Architektur betrachtet werden, in der eine Vorsteuerung in Kombination mit einem Gain-Scheduling PID-Regler betrieben wird [1] (zum Gain-Scheduling siehe [2, 3]). Die Vorsteuerung basiert dabei auf einem inversen stationären Modell der Ladedruckstrecke und dient damit dem Erzeugen stationärer Anteile des Stellsignals in Abhängigkeit von Motordrehzahl und Solladedruck. Dem Regler obliegt in diesem Konzept das Ausregeln von Modellfehlern und Störungen.

Aktuelle Veröffentlichungen lassen sich in verschiedene Kategorien einteilen auf die im Folgenden einzeln eingangen wird. Anschließend wird die vorliegende Veröffentlichung selbst kategorisiert und von anderen Veröffentlichungen abgegrenzt.

Ein wichtiges Unterscheidungsmerkmal verschiedener Arbeiten zur Ladedruckregelung ist die Art des berücksichtigten Verbrennungsmotors. Im Wesentlichen betrachten die Veröffentlichungen entweder Diesel- oder Ottomotoren. Entsprechend dem Fokus der vorliegenden Veröffentlichung, wird im Folgenden auf Arbeiten zu Ottomotoren eingegangen.

Ein Teil der Publikationen basiert ausschließlich auf simulativen Untersuchungen, während andere Arbeiten auch oder ausschließlich experimentelle Ergebnisse präsentieren (z.B. [4, 5]).

In aktuellen Veröffentlichungen kommen verschiedenste Regelungsverfahren wie z.B. Internal Model Control ([1, 4, 6, 7]), Fuzzy-Regelung ([8–10]) oder modellprädiktive Regelungsverfahren ([11, 12]) zum Einsatz. In diesen Kontext passen Veröffentlichungen, die sich mit der nichtlinearen Modellierung der Ladedruckstrecke beschäftigen. Beispielsweise wird in [13] ein LPV-Modell präsentiert. Nichtlineare physikalische Modelle werden in [14–16] präsentiert und in [17] wird die Reduktion solcher Modelle thematisiert.

Ein weiteres Unterscheidungsmerkmal sind die berücksichtigten Systemgrenzen. Teilweise wird die Ladedruckstrecke in Form eines Eingrößensystems angenommen ([4]), alternativ werden mehrere Ein- und oder Ausgänge betrachtet. Eine Kombination von Reglerausgängen bilden Beispielsweise Ladedrucksteller und Drosselklappe ([18, 19]).

Zahlreiche Veröffentlichungen beschäftigen sich mit gewöhnlichen Turboladern, während andere Arbeiten explizit komplexere Konzepte, wie eine mehrstufigen Aufladung [11], thematisieren.

Die vorliegende Arbeit stellt ein serientaugliches Konzept und zugehörige experimentelle Ergebnisse für einen Motor mit gewöhnlichem einstufigen Turbolader vor. Analog zum Stand der Technik ist:

- Die Betrachtung Strecke als Eingrößensystem,
- die verwendete Reglerstruktur, wobei jedoch die Komplexität der Vorsteuerung erheblich reduziert ist,
- das klassische Gain-Scheduling.

Das vorgeschlagene Regelungskonzept für den Ladedruck beinhaltet darüber hinaus zusätzlich eine dynamische Anstiegsbegrenzung der Führungsgröße zur Verhinderung von Windup-Effekten in Folge von Änderungen der Führungsgröße entsprechend [20].

Wesentliches Unterscheidungsmerkmal zum Stand der Technik ist das Parametrierungsverfahren, auf das im folgenden Abschnitt eingegangen wird.

### 1.1.2 Entwicklung der $H_{\infty}$ -optimalen Regelung

Das erarbeitete Konzept zur Parametrierung eines insgesamt nichtlinearen Ladedruckreglers zeichnet sich durch jeweils  $H_{\infty}$ -optimale Parametrierung der im Kern des Gain-Scheduling-Konzeptes vorhandenen linearen, strukturell vorgegebenen Arbeitspunktregler aus.

Klassische Verfahren zur Berechnung norm- und speziell  $H_{\infty}$ -optimaler Regler basieren auf der Lösung geköpelter algebraischer Riccati-Gleichungen [21, 22] oder konvexer Optimierungsprobleme auf Basis linearer Matrixungleichungen (LMI) [23–25]. Ohne weitere Maßnahmen resultieren aus der Verwendung derartiger Ansätze strukturell nicht eingeschränkte Regler mit einer Ordnung entsprechend der Ordnung der erweiterten Strecke.

Innerhalb der vorliegenden Arbeit werden strukturell beschränkte Regler angenommen. Diese Annahme erlaubt die Festlegung einer Reglerordnung sowie einer Reglerstruktur vor der eigentlichen Reglersynthese. Diese künstlich anmutende und gegebenenfalls einschränkende Festlegung der Struktur hebt den wesentlichen Nachteil klassischer  $H_{\infty}$ -optimaler Regler, die vergleichsweise hohe Reglerordnung, auf. Grundsätzlich sind bei dem verwendeten Verfahren jegliche lineare Reglerstrukturen zulässig. Die normoptimale Auslegung von Reglern mit einem und zwei Freiheitsgraden ist möglich. Insbesondere erlaubt das Vorgehen der Entwurf von Reglern in einer Struktur, für die vollständige Akzeptanz bei mit der praktischen Reglervalidierung betrauten Ingenieuren vorliegt.

Die signifikanten Vorteile, die durch den Einsatz  $H_{\infty}$ -optimaler strukturell beschränkter Regler zu erzielen sind, kommen zum Preis eines mathematisch komplexeren Syntheseproblems. Das zugeordnete Optimierungsproblem ist im Allgemeinen ein nichtkonvexes Problem dessen Lösung als nicht trivial gilt [26]. Das an dieser Stelle verwendete Verfahren zur Reglersynthese geht auf [26] zurück. Der dortige Ansatz schlägt eine unmittelbare Minimierung

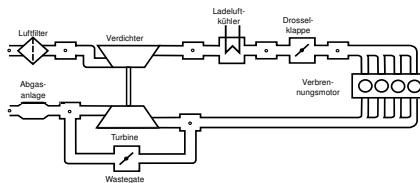


Abb. 1: Schematischer Aufbau des Luftsystems eines turboaufgeladenen Ottomotors.

der  $H_\infty$ -Norm geeignet festzulegender Performance-Funktionen vor und geht damit von einem nichtkonvexen und zudem nichtglatten, aber Clarke-subdifferenzierbarem, Optimierungsproblem ([27, 28]) aus. Für das dazu genutzte Abstiegsverfahren findet sich der Beweis der Konvergenz hinsichtlich eines lokalen Extremums in [29, 30].

## 1.2 Strukturierung dieser Arbeit

Im Folgenden Abschnitt wird zunächst das betrachtete System und anschließend die identifikationsbasierte Gewinnung mathematischer Systembeschreibungen für den Reglerentwurf dargestellt. Daran schließt sich in Abschnitt 3 die Vorstellung des Regelungskonzepts und der Entwurfssystematik der grundlegenden  $H_\infty$ -optimalen Regler an. Die unter Verwendung der in Abschnitt 3 entworfenen Regler erzielten experimentellen Ergebnisse werden in Abschnitt 4 diskutiert. Abschließend wird der Inhalt dieser Publikation in Abschnitt 5 zusammengefasst und ein Ausblick auf zukünftige Herausforderungen gegeben.

## 2 Systembeschreibung

Im Folgenden wird zunächst die betrachtete Regelstrecke im Kontext des Ottomotors verbal beschrieben, bevor die zur Reglersynthese verwendeten mathematischen Modelle eingeführt werden.

### 2.1 Verbale Beschreibung der Ladedruckstrecke

Bei dem zu regelnden dynamischen System handelt es sich um die Ladedruckstrecke eines modernen turboaufgeladenen Ottomotors. Die Ladedruckstrecke ist ein Teil des Luftsystems von Motoren, das schematisch in Abb. 1 dargestellt ist.

Um das vom Fahrer gewünschte Vortriebsmoment bereitstellen zu können, ist eine definierte Frischluftmasse in den Zylindern erforderlich. Im Rahmen herkömmlicher Regelungskonzepte wird die Füllung der Zylinder mit Frischluft in Abhängigkeit vom betrachteten Arbeitspunkt entweder durch die Drosselklappe oder durch das Stellelement des Turboladers vorgegeben. Nur in einem eng beschränkten Arbeitsbereich werden beide Stellglieder gleichzeitig aktuiert. Der Turbolader besteht aus einer Turbine und einem Verdichter, die über eine Welle verbunden sind. Der Verdichter wird von Frischluft durchströmt, und sorgt somit für eine Erhöhung der Frischluftmasse. Im Brennraum wird der Luft Kraftstoff zugeführt und das Gemisch verbrannt. Nach der Verbrennung werden die Abgase der Turbine zugeleitet, welche die im Abgas enthaltene Enthalpie in mechanische Energie für den Verdichter umwandelt. Über ein Wastegate ist es möglich einen Teil der Abgase an der Turbine vorbei zu leiten und damit die Leistungsaufnahme der Turbine zu regulieren.

Die Ladedruckstrecke ist hier durch das dynamische Übertragungsverhalten zwischen einem elektrisch aktuierten Wastegate als Stellelement und dem Ladedruck als Messgröße definiert. Vereinfachend wird im Folgenden eine vollständige Öffnung der Drosselklappe angenommen und damit der Betrieb des Motors im sogenannten aufgeladenen Bereich vorausgesetzt.

Die in dieser Publikation dargestellten experimentellen Resultate gehen auf Messungen an einem Motorprüfstand zurück.

### 2.2 Mathematische Modellierung der Ladedruckstrecke

Der modellbasierte Entwurf einer Ladedruckregelung setzt ein mathematisches Modell des zu regelnden dynamischen Prozesses voraus. In Abb. 2 ist der für die Ladedruckregelung zu berücksichtigende Arbeitsbereich in Abhängigkeit von Motordrehzahl  $n_M$  und Ladedruck  $p_L$  dargestellt. Die über den betrachteten Bereich der Motordrehzahl

nahezu konstante untere Schranke des zulässigen Ladedrucks ergibt sich durch die Bedingung einer vollständig geöffneten Drosselklappe. Die drehzahlabhängige obere Schranke des zulässigen Ladedrucks zeigt den charakteristischen Verlauf. Über den so beschriebenen Arbeitsbereich ist das dynamische Verhalten des Ladedrucks nichtlinear.

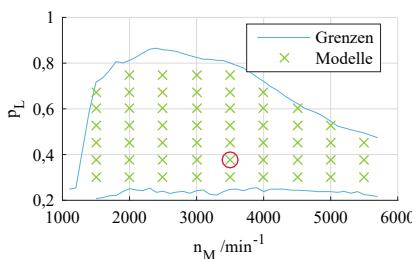


Abb. 2: Arbeitsbereich der Ladedruckregelung und Arbeitspunkte der lokalen linearen Modelle.

und Drehzahl als ausreichendes Maß. Als Anhaltspunkt für einen ausreichenden Anhaltspunkt für einen ausreichenden Robustheit auf, um alle im Sinne von  $p_L$  und  $n_M$  benachbarten linearen Systeme zu stabilisieren.

Der Identifikationsprozess an den einzelnen Arbeitspunkten basiert auf der jeweiligen Anregung der Ladedruckstrecke durch deterministische Testsignale mit systemspezifisch angepasstem Leistungsdichtespektrum und der Messung des Ladedrucks in Folge der genannten Anregung. Auf Basis der Identifikationsmessungen erfolgt in einem Zwischenschritt für jeden Arbeitspunkt die Schätzung eines nichtparametrischen Modells in Form eines Frequenzganges.

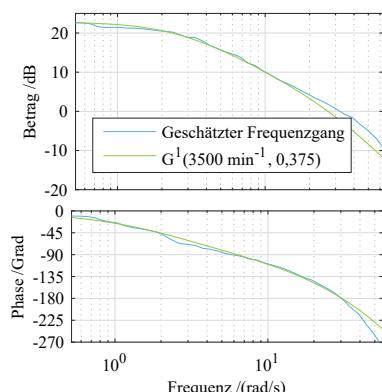


Abb. 3: Bodediagramm: Geschätzter Frequenzgang und Übertragungsfunktion  $G^1(3000 \text{ min}^{-1}, 0,375)(s)$ .

renden linearen Modelle wird anhand des NRMSE („Normalized Root Mean Square Error“) evaluiert ([31]). Stellvertretend für die im Rahmen der Identifikation erzielten Identifikationsergebnisse sind in Abb. 3 und Abb. 4 Frequenzbereichs- und Zeitbereichsdaten für den in Abb. 2 hervorgehobenen Fall mit  $n_M = 3000 \text{ min}^{-1}$  und  $p_L = 0,375$  dargestellt. Der Einfachheit halber wird der Index für diesen Fall im Folgenden zu  $i_\Sigma = 1$  gewählt.

Im Bodediagramm (Abb. 3) ist die gute Übereinstimmung zwischen nichtparametrischem Modell und dem Frequenzgang des parametrischen Modells zu erkennen. Abb. 4 zeigt, dass das parametrische Modell  $G^1(s)$  auch die Zeitdaten in einem ausreichenden Intervall gut annähert. Für das gewählte Beispiel beträgt der NRMSE ca. 0,25.

Im Hinblick auf das vorgeschlagene klassische Gain-Scheduling-Konzept wird die Erzeugung mathematischer Modelle auf die Identifikation einer endlichen Anzahl  $n_\Sigma = 52$  lokal gültiger linearer zeitinvarianter Systeme  $\{\Sigma_L^{i_\Sigma}\}_{i_\Sigma \in \mathcal{I}}$  mit  $\mathcal{I} = \{1, 2, \dots, n_\Sigma\}$  zurückgeführt.

Eine Parametrierung der  $\{\Sigma_L^{i_\Sigma}\}_{i_\Sigma \in \mathcal{I}}$  erfolgt auf Basis von  $n_\Sigma$  Wertepaaren aus Ladedruck und Drehzahl, deren Verteilung Abb. 2 zu entnehmen ist. Die so definierten Arbeitspunkte sind derart zu wählen, dass die Überdeckung der Gültigkeitsbereiche aller lokalen Systembeschreibungen den gesamten Arbeitsbereich der Ladedruckregelung erfasst [2].

Die Auswahl der Arbeitspunkte zur Festlegung einer Diskretisierung des gesamten Arbeitsbereichs kann grundsätzlich auf Basis verschiedener Abstandsmaße erfolgen. Für das vorliegende System erweisen sich hinreichend kleine euklidische Abstände von Ladedruck

und Drehzahl als ausreichendes Maß. Als Anhaltspunkt für einen hinreichend kleinen Abstand weist jeder an einem gegebenen Arbeitspunkt entworfene Regler ausreichend Robustheit auf, um alle im Sinne von  $p_L$  und  $n_M$  benachbarten linearen Systeme zu stabilisieren.

Der Identifikationsprozess an den einzelnen Arbeitspunkten basiert auf der jeweiligen Anregung der Ladedruckstrecke durch deterministische Testsignale mit systemspezifisch angepasstem Leistungsdichtespektrum und der Messung des Ladedrucks in Folge der genannten Anregung. Auf Basis der Identifikationsmessungen erfolgt in einem Zwischenschritt für jeden Arbeitspunkt die Schätzung eines nichtparametrischen Modells in Form eines Frequenzganges.

Auf Basis der resultierenden Frequenzgänge werden die Struktur und Ordnung eines in Form einer Übertragungsfunktion

$$G^{i_\Sigma}(s) = \frac{K_0^{i_\Sigma} \cdot e^{-T_t \cdot s}}{(T_1^{i_\Sigma} \cdot s + 1) (T_2^{i_\Sigma} \cdot s + 1)}, \quad i_\Sigma \in \mathcal{I} \quad (1)$$

gegebenen parametrischen Modells festgelegt. Die voranstehende Übertragungsfunktion dient als strukturelle Vorgabe für jede der  $n_\Sigma$  linearen Systembeschreibungen. In (1) wird eine über alle Arbeitspunkte konstante Totzeit  $T_t = 30 \text{ ms}$  angenommen, ferner gilt  $f^{i_\Sigma} = f(p_L^{i_\Sigma}, n_M^{i_\Sigma})$  für alle Koeffizienten der Übertragungsfunktion  $G^{i_\Sigma}(s) = G(p_L^{i_\Sigma}, n_M^{i_\Sigma})(s)$ . Damit verbleiben in (1) für jeden Arbeitspunkt drei Koeffizienten, um die Übertragungsfunktion an die zugehörigen lokalen Identifikationsmessungen anzupassen.

Das zur Schätzung der Koeffizienten eingesetzte Verfahren beruht im Kern auf der Methode der Hilfsvariablen. An dieser Stelle ist allerdings auch der Einsatz alternativer Methoden zur Parameterschätzung zeitkontinuierlicher Systeme denkbar ([31–34]).

Die Güte der aus der Parameterschätzung resultierenden linearen Modelle wird anhand des NRMSE („Normalized Root Mean Square Error“) evaluiert ([31]). Stellvertretend für die im Rahmen der Identifikation erzielten Identifikationsergebnisse sind in Abb. 3 und Abb. 4 Frequenzbereichs- und Zeitbereichsdaten für den in Abb. 2 hervorgehobenen Fall mit  $n_M = 3000 \text{ min}^{-1}$  und  $p_L = 0,375$  dargestellt. Der Einfachheit halber wird der Index für diesen Fall im Folgenden zu  $i_\Sigma = 1$  gewählt.

Im Bodediagramm (Abb. 3) ist die gute Übereinstimmung zwischen nichtparametrischem Modell und dem Frequenzgang des parametrischen Modells zu erkennen. Abb. 4 zeigt, dass das parametrische Modell  $G^1(s)$  auch die Zeitdaten in einem ausreichenden Intervall gut annähert. Für das gewählte Beispiel beträgt der NRMSE ca. 0,25.

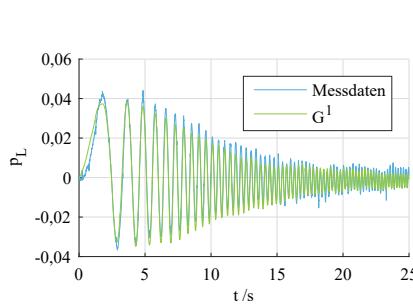


Abb. 4: Exemplarischer Vergleich eines Modells mit gemessenen Daten von einem Chirp (bis ca. 5 Hz/31,4  $\frac{\text{rad}}{\text{s}}$ ).

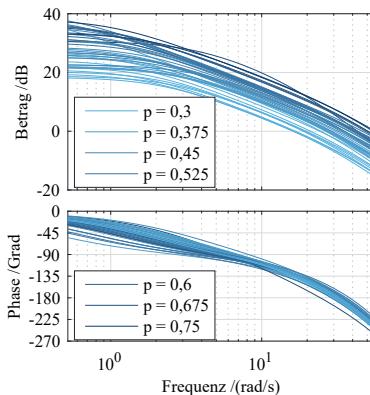


Abb. 5: Bodediagramme: Frequenzgänge aller identifizierten lokalen linearen Modelle.

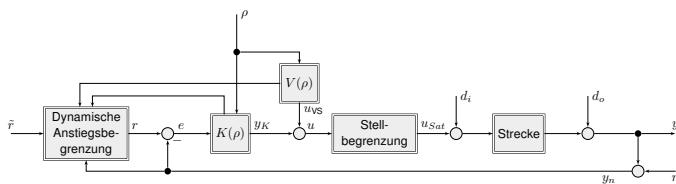


Abb. 6: Struktur der Ladedruckregelung, bestehend aus Gain-Scheduling-Regler  $K(\rho)$ , Störgrößenaufschaltung  $V(\rho)$  sowie dynamischer Anstiegsbegrenzung als Anti-Windup-Maßnahme.

In Abb. 5 sind zusätzlich die Frequenzgänge aller aus dem Identifikationsprozess resultierender Übertragungsfunktionen dargestellt. Innerhalb der Schar linearer Systeme variiert die stationäre Verstärkung zwischen 18,4 dB und 40,5 dB. Der Dominante Pol der Systeme liegt zwischen  $-0,3855 \text{ s}^{-1}$  und  $-3,634 \text{ s}^{-1}$ . Beide Parameter variieren also in etwa um den Faktor 10.

Angefangen bei der Durchführung der Identifikationsmessungen bis hin zur qualitativen Evaluierung der resultierenden linearen Modelle lässt sich der geschilderte Identifikations-Prozess weitestgehend automatisieren und damit in kurzer Zeit sehr effizient durchführen.

### 3 Regelung

Einleitend enthält der vorliegende Abschnitt einen Überblick über die in Abb. 6 schematisch dargestellte Ladedruckregelung mit Schwerpunkt auf dem Gain-Scheduling-Konzept, der stationären Störgrößenaufschaltung sowie der dynamischen Anstiegsbegrenzung als Anti-Windup-Maßnahme. Daran schließt sich eine detaillierte Betrachtung des Entwurfs der  $H_\infty$ -optimalen lokalen strukturierten Regler an, die die Basis des eingesetzten Gain-Scheduling-Konzeptes bilden.

#### 3.1 Konzept der Ladedruckregelung

Bei dem zur Regelung der nichtlinearen Strecke eingesetzten Gain-Scheduling Regler hängt das Regelgesetz

$$u(t) = K(\rho)(r(t) - y(t)) + V(\rho) \quad (2)$$

über dem Arbeitsbereich des Ladedrucks von dem Parametervektor  $\rho \in \mathbb{R}^{n_\rho}$  ab. Die Synthese des Gain-Scheduling-Reglers

$$K(\rho) = \left[ \begin{array}{c|c} A_k(\rho) & B_k(\rho) \\ \hline C_k(\rho) & D_k(\rho) \end{array} \right] \quad (3)$$

$$= \left[ \begin{array}{cc|c} 0 & 0 & 1 \\ 0 & -\frac{1}{T_f(\rho)} & \frac{K_D(\rho)}{T_f(\rho)} \\ \hline K_I(\rho) & -\frac{1}{T_f(\rho)} & K_P(\rho) + \frac{K_D(\rho)}{T_f(\rho)} \end{array} \right] \quad (4)$$

wird durch die Diskretisierung des durch Motordrehzahl und Ladedruck  $\rho = (\rho_1 \ \rho_2) = (n_M \ p_L) = (n_M \ n_L)$  parametrisierten Arbeitsbereichs der Strecke auf eine endliche Anzahl  $n_L = n_\Sigma$  lokaler linearer Reglerentwürfe an den in Abb. 2 zu erkennenden Arbeitspunkten zurückgeführt. Neben  $n_L = n_\Sigma$  wird eine passende Sortierung von Reglern und Strecke angenommen, sodass im Folgenden  $i = i_K = i_\Sigma$  gilt.

Jedem lokalen Reglerentwurf liegt eine lokale Streckenbeschreibung zu Grunde. Unter Berücksichtigung der Einschränkung auf lokale PID-Regler und der abkürzenden Notation  $f(\rho_i) = f^i$  gilt

$$K^i = \left[ \begin{array}{c|c} A_k^i & B_k^i \\ \hline C_k^i & D_k^i \end{array} \right] = \left[ \begin{array}{cc|c} 0 & 0 & 1 \\ 0 & -\frac{1}{T_f^i} & \frac{K_D^i}{T_f^i} \\ \hline K_I^i & -\frac{1}{T_f^i} & K_P^i + \frac{K_D^i}{T_f^i} \end{array} \right] \quad (5)$$

für  $i = 1, 2, \dots, n_\Sigma$ . Als nominelle Strecke liegt dem Entwurf des  $i$ -ten Reglers dabei gerade die Übertragungsfunktion  $G^i(s)$  zu Grunde.

Aus der im folgenden Abschnitt detailliert beschriebenen Reglersynthese an jedem Arbeitspunkt resultieren jeweils die Reglerkoeffizienten  $K_D^i, K_I^i, K_P^i, T_f^i$ . Diese Koeffizienten dienen als Stützwerte einer linearen Interpolation. Diese ermöglicht zu jedem Zeitpunkt für beliebige, innerhalb des Arbeitsbereichs gelegene, Parametervektoren  $\rho$  die Berechnung der aktuellen Systemmatrizen des Gain-Scheduling Reglers entsprechend (3). Abb. 7 zeigt die aus dem Reglerentwurf resultierenden Kennfelder der Reglerkoeffizienten.

Der verbleibende Anteil des Stellgesetzes (2) besteht aus der in Abb. 8 dargestellten statischen Kennlinie, die sich als Störgrößenaufschaltung in Abhängigkeit von der Drehzahl  $n_M$  interpretieren lässt. Im Unterschied zu verschiedentlich eingesetzten stationären Vorsteuerungen dient die Führungsgröße nicht als Eingang der Kennlinie. Experimentelle Ergebnisse zeigen, dass die Störgrößenaufschaltung gut geeignet ist den Einfluss schneller Drehzahländerungen auf den Ladedruck auszugleichen.

Neben dem Regelgesetz entsprechend (2) erfolgt eine dynamische Anstiegsbegrenzung der Führungsgröße zur Verhinderung von Windup-Effekten in Folge von Änderungen der Führungsgröße, es gilt

$$r(t) = \begin{cases} \tilde{r}_{\max}(t) & \text{für } u(t) \geq u_{\max}(V(\rho)), \\ \tilde{r}(t) & \text{für } u_{\max}(V(\rho)) > u(t) > u_{\min}(V(\rho)), \\ \tilde{r}_{\min}(t) & \text{für } u_{\min}(V(\rho)) \geq u(t). \end{cases} \quad (6)$$

Unter Vernachlässigung der Abhängigkeit von  $\rho$  und der Annahme der Invertierbarkeit von  $D_k$  für alle  $\rho$  ergeben sich die dynamischen Grenzen der Führungsgröße zu

$$\tilde{r}_{\max}(t) = D_k^{-1} u_{\max} - D_k^{-1} C_k x_k(t) + y_n(t) \quad (7)$$

und

$$\tilde{r}_{\min}(t) = D_k^{-1} u_{\min} - D_k^{-1} C_k x_k(t) + y_n(t). \quad (8)$$

Die eingesetzte Anti-Windup Maßnahme erlaubt zu jedem Zeitpunkt die maximal mögliche Änderung der Führungsgröße, sodass gerade keine Verletzung der in Abhängigkeit von der Vorsteuerung  $V(\rho)$  dynamisch veränderlichen Stellbegrenzungen erfolgt. Die dynamische Anstiegsbegrenzung entsprechend (6) erfordert die Kenntnis des aktuellen Zustandsvektors des Reglers, beruht allerdings ausschließlich auf der Lösung algebraischer Gleichungen und ist damit numerisch effizient umsetzbar.

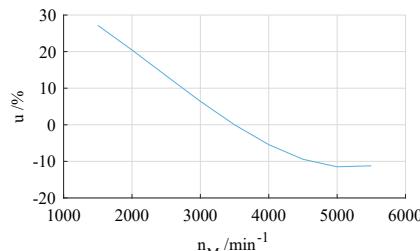


Abb. 8: Kennlinie der drehzahlabhängigen Störgrößenaufschaltung  $V(\rho)$ .

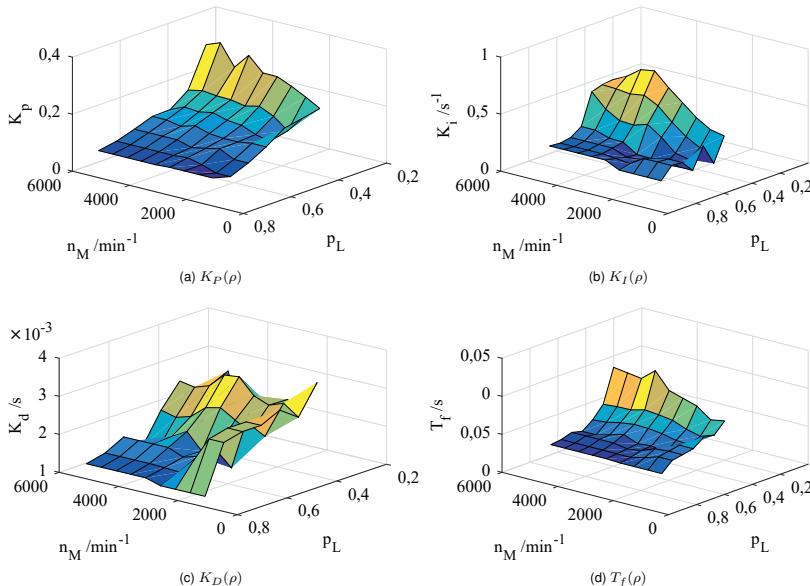


Abb. 7: Kennfelder der aus dem Entwurf an verschiedenen Arbeitspunkten resultierenden Reglerkoeffizienten.

### 3.2 Das Entwurfsproblem linearer strukturierter $H_\infty$ -optimaler Regler

Der Einsatz eines Reglerentwurfsverfahrens zur Formung charakteristischer Übertragungsfunktionen des geschlossenen Regelkreises („closed-loop-shaping“) erlaubt auf eingängige Weise die Einbeziehung quantitativer Forderungen an das Verhalten des geschlossenen Regelkreises in den Entwurfsprozess. Bei dieser anforderungsgetriebenen Form der Reglerauslegung lassen sich *a priori*, gegebenenfalls im Dialog mit dem Anwender, beispielsweise quantitative Robustheitseigenschaften, Performance-Forderungen und die Nutzung der Stellgröße spezifizieren. Durch die Einbeziehung strukturierter Regler wird die Möglichkeit zur im Sinne geeigneter Kriterien optimaler Parameterierung im Einsatz befindlicher bzw. durch den Software-Entwicklungsprozess unverrückbar vorgegebener beliebiger linearer Reglerstrukturen eröffnet. Insbesondere erlaubt das Vorgehen den Entwurf von Reglern in bei anwendungsorientierten Ingenieuren akzeptierter Struktur.

In Anlehnung an das bekannte  $H_\infty$ -Standard-Entwurfsproblem

$$\min_K \|\mathcal{F}_l(P, K)\|_\infty, \quad (9)$$

welches sich in der deutschsprachigen Literatur beispielsweise in [35–37] findet, lässt sich das Entwurfsproblem strukturierter  $H_\infty$ -optimaler Regler formal durch eine Einschränkung der Menge der zulässigen Regler auf eine Menge von zulässigen Reglern mit gewünschter Struktur  $\mathcal{K}$  ausdrücken. Im Unterschied zum  $H_\infty$ -Standard-Entwurfsproblem ist das durch die Berücksichtigung strukturell eingeschränkter Regler resultierende  $H_\infty$ -Entwurfsproblem im Allgemeinen nichtkonvex [26].

Die algorithmische Lösung des Entwurfsproblems strukturierter  $H_\infty$ -optimaler Regler beruht an dieser Stelle auf den in [26, 38] eingeführten Ansätzen. Diese Ansätze nutzen Methoden der nichtglatten Optimierung [27, 28, 39] zur Lösung des durch Berücksichtigung der  $H_\infty$ -Norm im Kostenfunktional nichtglatten Optimierungsproblems. Bei diesem Vorgehen entspricht die Anzahl der Optimierungsvariablen der Anzahl der freien Reglerparameter  $p_k$  und ist somit unabhängig von der Ordnung der erweiterten Strecke.

Während herkömmliche Lösungsansätze für das  $H_\infty$ -Standard Entwurfsproblem entsprechend (9) im Kostenfunktional die  $H_\infty$ -Norm der Übertragungsmatrix  $\mathcal{F}_l(P, K)$  enthalten, zeichnen sich die an dieser Stelle genutzten An-

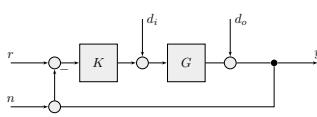


Abb. 9: Standardregelkreis des Entwurfsproblems lokal linearer Ladedruckregler.

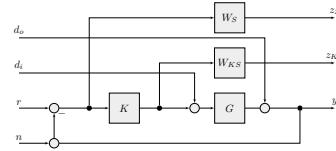


Abb. 10: Erweiterter geschlossener Regelkreis des Entwurfsproblems lokal linearer Ladedruckregler.

sätze durch eine weniger konservative Formulierung aus. Es wird unmittelbar und ausschließlich das Maximum der  $H_{\infty}$ -Normen der Performance-Pfade minimiert.

### 3.3 Entwurf lokal linearer strukturierter $H_{\infty}$ -optimaler Regler für den Ladedruck

Dem Entwurfsproblem linearer Regler für den Ladedruck liegt die durch Abb. 9 gegebene Reglerstruktur mit einem Freiheitsgrad zugrunde. Die strukturelle Festlegung der  $K^i(s) = K(p^i)(s)$  an den  $n_{\Sigma}$  Stützstellen als PID-Regler gemäß (5) führt für jeden Arbeitspunkt auf die freien Parameter  $K_P^i, K_I^i, K_D^i, T_f^i$  und somit

$$p^i = (K_P^i \ K_I^i \ K_D^i \ T_f^i)$$

sowie  $p_K = 4$  in jedem einzelnen Entwurfsproblem.

Die Definition der Performance-Pfade im Entwurfsproblem basiert auf dem erweiterten geschlossenen Regelkreis entsprechend Abb. 10.

Um die Robustheit und das Führungsübertragungsverhalten des geschlossenen Regelkreises gezielt beeinflussen zu können wird die gewichtete Sensitivitätsfunktion des geschlossenen Regelkreises

$$T_{r \rightarrow z_S}(K^i(s)) = W_S(s)S^i(s) \quad (10)$$

$$= W_S(s)(1 + G^i(s)K^i(s))^{-1} \quad (11)$$

in das Kostenfunktional einbezogen. Mittels

$$T_{d_o \rightarrow z_{K^i(S)}}(K^i(s)) = -W_{KS}(s)K^i(s)S^i(s) \quad (12)$$

wird ferner die Stellgröße im geschlossenen Regelkreis geformt. Für den Entwurf der Arbeitspunktregler mit einem Freiheitsgrad gilt demnach  $n_Z = 2$  sowie

$$\mathcal{Z} = \{r \rightarrow z_S, d_o \rightarrow z_{K^i(S)}\}.$$

Der Freiheitsgrad einer arbeitspunktabhängigen Wahl der Gewichtungsfunktionen  $W_S(s)$  und  $W_{KS}(s)$  bleibt ungenutzt.

Die frequenzabhängige Beschränkung der im Entwurfsproblem inkludierten Performance-Pfade wird durch die Festlegung der Gewichtungsfunktionen zu

$$W_S(s) = \frac{1,15 \cdot (s + 0,0025)}{(s + 5,5)} \quad (13)$$

und

$$W_{KS}(s) = \frac{(s + 600)^4}{100 \cdot (s + 190)^4} \quad (14)$$

erreicht.

Exemplarisch für die an allen Arbeitspunkten durchgeführten Reglerentwürfe, werden an dieser Stelle die Resultate des Reglerentwurfs am Arbeitspunkt  $i = 1$  vorgestellt.

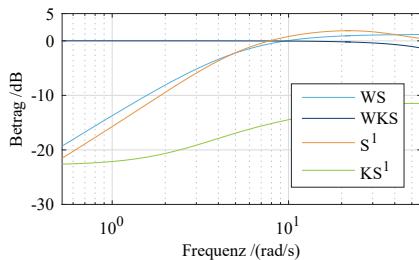


Abb. 11: Betragsverlauf der Frequenzgänge der Gewichtungsfunktionen  $W_S$  und  $W_{KS}$  sowie der zugehörigen charakteristischen Übertragungsfunktionen  $S$  und  $KS$  des linearen Standardregelkreises am durch  $n_M = 3000 \text{ min}^{-1}$  und  $p_L = 0,375$  definierten Arbeitspunkt.

werten. Der minimale Abstand der Kreisverstärkung  $L^1(s) = G^1(s)K^1(s)$  zum kritischen Punkt  $-1$  im Nyquist-Diagramm beträgt  $(M_S^1)^{-1} \approx 0,79$ . Dementsprechend verfügt der resultierende Regelkreis über gute Robustheitseigenschaften.

Jeder der entworfenen Arbeitspunktregler ist allein auf Basis der Robustheitsforderung entsprechend (10) und (13) in der Lage alle umliegenden Strecken zu stabilisieren. Als Maß für die Robustheit der lokal linearen Regelkreise sei an dieser Stelle der Wertebereich der Maximalwerte  $M_S^i$  der einzelnen Sensitivitätsfunktionen  $S^i$  über den Arbeitsbereich angeführt. Die  $M_S^i$  liegen zwischen 1,23 und 1,31.

Den Nachweis der praktischen Eignung des Gain-Scheduling-Konzeptes zur Regelung des Ladedrucks erfolgt anhand einer experimentellen Evaluierung, deren Ergebnisse sich im nachfolgenden Abschnitt finden.

## 4 Ergebnisse

In diesem Abschnitt werden Ergebnisse präsentiert die mit dem im vorangegangenen Abschnitt beschriebenen Regelungskonzept am Prüfstand erzielt wurden. Dazu erfolgt zunächst eine Beschreibung der Testszenarien.

### 4.1 Versuchsbeschreibung

Die durchgeführten Versuche unterscheiden sich auf zwei Ebenen. Die erste Unterscheidung betrifft die Anregung des Solladedrucks. Dieser wird

- (1) direkt variiert
- (2) indirekt über das Fahrpedalsignal variiert.

Eine direkte Variation des Solladedrucks (Variante 1) ermöglicht die Verwendung von beliebigen Trajektorien und somit die Betrachtung von Standardtestfällen wie Sollwertsprüngen. Durch die Anregung über das Fahrpedal (Variante 2) wird die Realitätsnähe der Versuche erhöht. Nachteilig ist, dass eine sprungförmige Änderung des Pedalwerts nicht zwingend zu einer sprungförmigen Änderung des Ladedrucksollwerts führt. Weiterhin ist die Abbildung von Pedalwert auf Solladedruck im Allgemeinen nichtlinear.

Weil die Lasteinheit des Motorprüfstands während der Versuche drehzahlgeregelt betrieben wird und kein Fahrzeugmodell in den Prüfstand integriert ist, ergibt sich die zweite Unterscheidungsebene der Versuche. Die Drehzahl wird während der Versuche

- (a) konstant gehalten
- (b) rampenförmig variiert.

Konstante Drehzahlen bei gleichzeitig varierender Last werden in realen Fahrsituationen im Allgemeinen nicht erreicht. Dennoch ist Variante 1 hilfreich, um die Qualität der Regler zu beurteilen, da in dieser das Scheduling nur in einer Dimension erfolgt. Die Vergleichbarkeit mit realen Fahrsituationen kann durch Variante b erhöht werden.

Abb. 11 zeigt die Betragsverläufe des Frequenzgangs der charakteristischen Pläne  $S^1(s)$  und  $K^1(s)S^1(s)$  des Standardregelkreises. Ferner sind die Verläufe der zugeordneten Gewichtungsfunktionen  $W_S(s)$  und  $W_{KS}(s)$  dargestellt. Abb. 11 zeigt, dass am betrachteten Arbeitspunkt im relevanten Frequenzbereich  $K^1(s)S^1(s)$  deutlich unterhalb der zugehörigen Schranke  $W_{KS}(s)$  verläuft und damit im zugehörigen linearen Regelkreis die quantitativen Anforderungen an die Nutzung der Stellgröße eingehalten werden.

Gleichzeitig verläuft  $S^1(s)$  in einem Frequenzband von etwa  $5 \text{ rad s}^{-1}$  bis  $40 \text{ rad s}^{-1}$  leicht oberhalb der Gewichtungsfunktion  $W_S(s)$  und für die maximale Verstärkung der Sensitivität gilt

$$M_S^1 = \max_{\omega} |S^1(i\omega)| \approx 1,27.$$

In Anbetracht der geringfügigen Überschreitung der vorgegebenen Schranke und des geringen  $M_S^1$  ist der Reglerentwurf an diesem Arbeitspunkt als erfolgreich zu beurteilen.

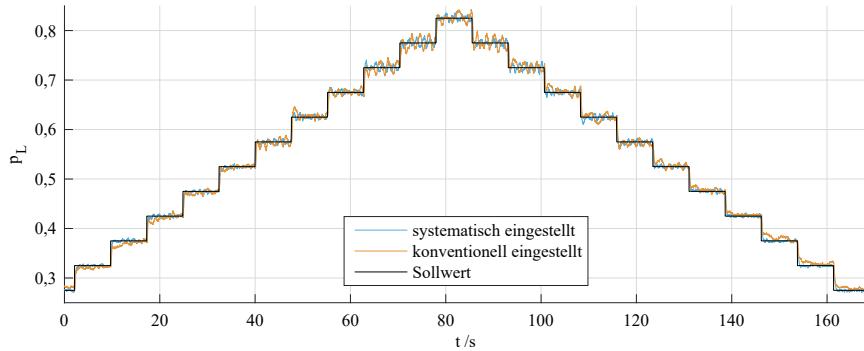


Abb. 12: Treppenförmiger Verlauf des Sollladedrucks bei  $2500 \text{ min}^{-1}$ .

Im Folgenden werden Ergebnisse vorgestellt, die mit dem in dieser Arbeit präsentierten Regelungskonzept experimentell erzielt wurden. Zu Vergleichszwecken werden auch Ergebnisse des konventionellen Reglers gezeigt. Die Reglervarianten werden im Folgenden als konventionell eingestellt und systematisch eingestellt bezeichnet.

#### 4.2 Sollladedrucksprünge

Zur Ermittlung des Führungsverhaltens werden Sollladedrucksprünge bei konstanter Drehzahl durchgeführt (Versuchsvariante 1a). Hier werden die Ergebnisse lokaler Sprünge mit verhältnismäßig geringer Höhe dargestellt.

Zur Überprüfung der Performance an einem gegebenen Arbeitspunkt werden Serien von Sollladedrucksprüngen geringer Sprunghöhe durchgeführt. In Abb. 12 sind die Ergebnisse dieser Versuche bei  $2500 \text{ min}^{-1}$  dargestellt. Es ist ersichtlich, dass die Performance des konventionell eingestellten Reglers einer größeren Streuung unterliegt, als jene des systematisch eingestellten Reglers. Weiterhin fällt auf, dass der Istdruck im höheren Ladedruckbereich stärkeren Schwingungen unterliegt als im niedrigeren Ladedruckbereich. Dabei weisen die Schwingungen im Fall des konventionell eingestellten Reglers eine deutlich höhere Amplitude als jene des systematisch eingestellten Reglers auf.

Zur Verbesserung der Übersichtlichkeit sind in Abb. 13 die positiven Sprünge aus Abb. 12 (bis  $t = 80 \text{ s}$ ) zeitlich übereinandergelegt. Die Druckverläufe sind jeweils in Unterabbildung (a) und (b) und die Stellgrößenverläufe in Unterabbildung (c) und (d) aufgetragen. Die Druckverläufe sind auf den Einheitssprung skaliert. In den Abbildungen stellen jeweils helle Linien niedrige und dunkle Linien hohe Ladedrücke dar.

Aus Abb. 13 ist ersichtlich, dass die Sprungantworten des konventionell eingestellten Reglers über den Arbeitsbereich stärker streuen und langsamer sind als die Sprungantworten des systematisch eingestellten Reglers. Dieser Eindruck wird durch die Ergebnisse in Tabelle 1 gestützt. Dort sind zwei Kriterien für die Regelgüte ausgewertet. Das erste ist die Zeit  $T_{0,63}$ , nach der 63% der Sprunghöhe erreicht sind. Für dieses Kriterium enthält die Tabelle Minimum und Maximum. Das zweite Kriterium ist die zeitbeschwere betragsslineare Regelfläche (ITAE - Integral of Time-weighted Absolute Error), für die

$$I = \int_0^{t_f} |e| \cdot t \cdot dt$$

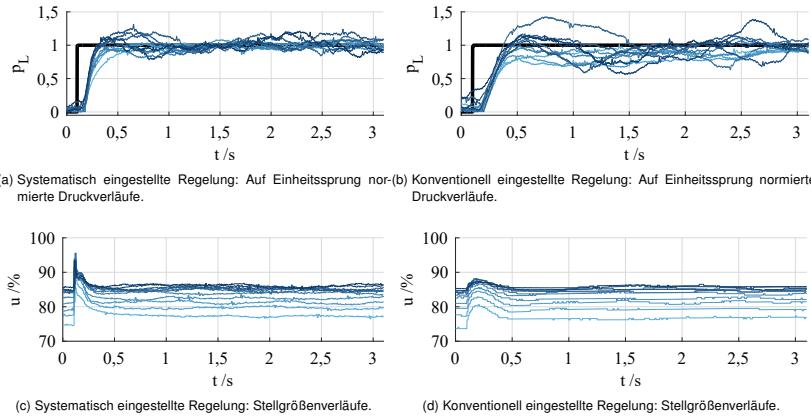
gilt. Für dieses Kriterium enthält die Tabelle Mittelwert M und Standardabweichung SD.

Die in  $T_{0,63}$  erkennbare Beschleunigung durch die systematische Parametrierung schlägt sich im Stellgrößenverlauf in deutlich höheren Ausschlägen unmittelbar nach dem Führungsgrößensprung nieder.

Für den ITAE ist der im Mittel durch die systematische Reglereinstellung nahezu halbierten Wert und die deutlich verbesserte Standardabweichung beachtenswert. Die Standardabweichung ist insbesondere für überlagerte Regelkreise in hierarchischen Regelungskonzepten bedeutsam. Die Absolutwerte der Re-

Tabelle 1: Vergleich der Regelgüte im Sollladedrucksprung.

	$T_{0,63} / \text{s}$		ITAE / $\text{s}^2$	
	Min.	Max.	M	SD
konventionell	0,19	0,26	0,603	0,206
systematisch	0,12	0,21	0,283	0,0862

Abb. 13: Serie positiver Solladedrucksprünge bei  $2500 \text{ min}^{-1}$ 

gelfehler am Ende des gezeigten Zeithorizonts sind für den systematisch eingestellten Regler sehr klein und liegen innerhalb des üblichen Rauschens. Insgesamt kann gezeigt werden, dass der systematisch eingestellte Regler bei der gegebenen Drehzahl über den gesamten Druckbereich gleichbleibend gute Ergebnisse mit geringer Variation erzielt.

### 4.3 Lastschlag

#### 4.3.1 Szenariobeschreibung

Ein herausforderndes Szenario für jede Ladedruckregelung besteht in einem schnellen durchtreten des Gaspedals. Am Prüfstand wird dieses Szenario durch einen gleichzeitigen Sprung auf dem Fahrpedalsignal und hochfahren der Drehzahl mit größtmöglicher Geschwindigkeit nachgebildet (Versuchsvariante 2b). Zu Beginn des Versuchs ist der Fahrpedalwert so gewählt, dass die Drosselklappe bereits vollständig geöffnet und somit die Ladedruckregelung für das Erreichen des Fahrerwunschknoten verantwortlich ist. In Abb. 14a ist dargestellt, wie dieses Szenario im Rahmen des vorliegenden Artikels durchgeführt wird. Zum Zeitpunkt  $t = 0$  wird der Pedalwert schlagartig auf 100 % und die Drehzahl innerhalb von ca. 2 s um  $2000 \text{ min}^{-1}$  erhöht. Da mit steigender Drehzahl der maximal zulässige Ladedruck sinkt, sinkt auch der Solladedruck für 100 % Pedal mit der Drehzahl und somit im dargestellten Fall mit der Zeit. Durch dieses Szenario werden in kurzer Zeit beide Scheduling-Parameter stark variiert.

#### 4.3.2 Ergebnisse

In Versuchen wird der dargestellte Lastschlag je 50-mal auf den konventionell eingestellten Regler und den systematisch eingestellten Regler aufgeprägt. Die Ergebnisse dieser Versuche sind in Abb. 14 dargestellt, wobei sich die Ladedruckverläufe in Unterabbildung (c) und die Stellgrößenverläufe in Unterabbildung (b) befinden.

Augenscheinlich sind die Ergebnisse des konventionell eingestellten Reglers mit einer erheblich größeren Streuung behaftet, als die Ergebnisse des systematisch eingestellten Reglers. In manchen Iterationen führt der konventionell eingestellte Regler zu einem erheblichen Überschwinger, der in anderen Iterationen ausbleibt. Ein möglicher Erklärungsansatz ist der große Anteil der Vorsteuerung an der Stellgröße im konventionell eingestellten Regler.

Auch nach  $t = 3 \text{ s}$  ist das Ladedruckband für den systematisch eingestellten Regler erheblich breiter. Am Ende der Drehzahlrampe beträgt die Regelabweichung für den systematisch eingestellten Regler sehr schnell ungefähr 0, und ist während der Drehzahlrampe über weite Bereiche auch sehr gering. Der konventionell eingestellte Regler erreicht lange Zeit den Solladedruck nicht.

Die Stellgrößenverläufen (Abb. 14b) unterscheiden sich wenig. Der größte Unterschied zwischen beiden Varianten findet sich kurz vor  $t = 1 \text{ s}$ . Zu diesem Zeitpunkt hat der Ladedruckverlauf des konventionell eingestellten Reglers,

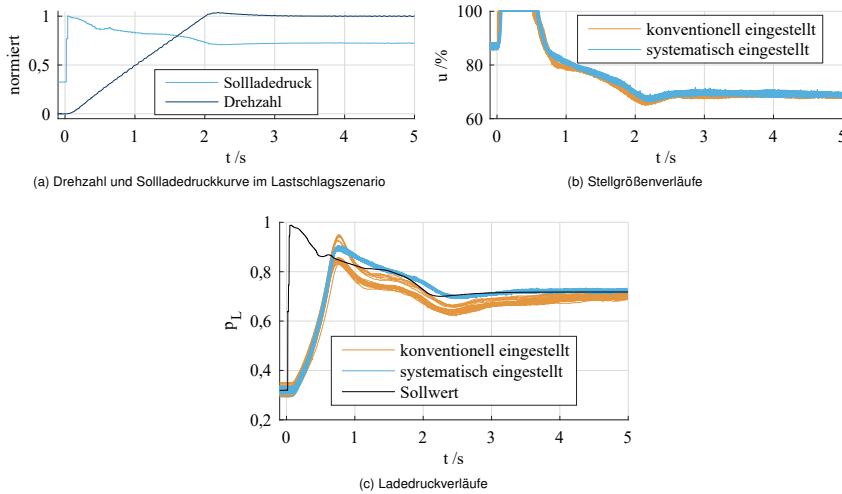


Abb. 14: Vergleich des Führungsverhaltens beider Regler im Fall eines Lastschlags.

im Gegensatz zum systematisch eingestellten Regler, einen stark negativen Gradienten.

Für die dargestellten Versuche sind die Mittelwerte und Standardabweichungen des ITAE-Kriteriums in Tabelle 2 dargestellt. Das signifikant verbesserte Fehlermaß unterstreicht erneut den Eindruck der besseren Qualität der Regelergebnisse des systematisch eingestellten Reglers.

Tabelle 2: Vergleich der Regelgüte im Lastschlag.

	ITAE / s <sup>2</sup>	
	M	SD
konventionell	0,458	0,0810
systematisch	0,151	0,00662

## 5 Zusammenfassung und Ausblick

Im vorliegenden Artikel wird ein systematischer Entwurfsprozess für eine Gain-Scheduling-Regelung auf Basis lokaler linearer  $H_{\infty}$ -optimaler Regler gegebener Struktur in Kombination mit einer einfachen Störgrößenaufschaltung und einem Anti-Windup-Konzept für die Ladedruckstrecke eines Ottomotors gezeigt.

Die durch umfangreiche experimentelle Erprobung an einem Prüfstand erzielten Resultate weisen eine signifikant erhöhte Regelgüte gegenüber einem

konventionell parametrierten Regler vergleichbarer Struktur auf. Dies unterstreicht deutlich die Eignung des vorgestellten Regelungskonzepts zur Regelung des Ladedrucks. Die im Entwurfsprozess inkludierte modellbasierte Synthese strukturierter  $H_{\infty}$ -optimaler Regler erfolgt zuverlässig auf Basis von Optimierungsalgorithmen zur Lösung nichtglatter Optimierungsprobleme. Der Entwurfsprozess erfordert keine komplexe nichtlineare Systembeschreibung. Die als Basis des Reglerentwurfs dienenden lokalen linearen Systembeschreibungen lassen sich effizient und zuverlässig durch Methoden der Systemidentifikation erzeugen. Das verwendete Anti-Windup-Konzept verursacht keinen zusätzlichen Entwurfsaufwand und ist mit vernachlässigbarem Rechenaufwand realisierbar.

Die Resultate verdeutlichen, dass auch ohne eine neue Reglerstruktur oder zusätzliche Algorithmen Potentiale in der Ladedruckregelung gehoben werden können. Durch die Möglichkeit zur  $H_{\infty}$ -optimalen Parametrierung beliebig strukturierter linearer Regler lässt sich der gezeigte Entwurfsprozess unmittelbar auf die Parametrierung verschiedener anderer bestehende Regelkreise aktueller Serienmotoren übertragen.

Durch das systematische Vorgehen im Rahmen des weitestgehend automatisierten Entwurfsprozesses bestehend aus Identifikation, Reglerentwurf und Reglervalidierung ergibt sich die Nachvollziehbarkeit intermediärer Resultate. Letztendlich resultieren aus dem Prozess reproduzierbare Reglerparametrierungen sowie serientaugliche Regler die eine hohe Regelgüte gewährleisten. Die Generierung zuverlässiger Regler geschieht unter gleichzeitiger Reduktion des Ressourcenbedarfs und Verringerung des Zeitaufwands.

Als finaler Nachweis zur Tauglichkeit des vorgestellten Konzepts zur Ladedruckregelung werden die gezeigten Prüfstandsversuche in Zukunft durch Erprobungen an Fahrzeugen ergänzt. Auf der theoretischen Seite ist eine Einbindung nichtlinearer Systemmodelle und damit der formale Nachweis der Stabilität des eingesetzten Gain-Scheduling-Konzeptes denkbar.

## Literatur

- [1] A. Thomasson, L. Eriksson, O. Leufven, and P. Andersson. Wastegate actuator modeling and model-based boost pressure control. In *2009 IFAC Workshop on Engine and Powertrain Control, Simulation and Modeling, November 30th-December 2nd, Paris, France*, pages 87–94, 2009.
- [2] J. Adamy. *Nichtlineare Systeme und Regelungen*. Springer Berlin Heidelberg, Berlin Heidelberg, 2., bearb. u. erw. aufl. 2014 edition, 2014.
- [3] K. J. Aström and B. Wittenmark. *Adaptive Control*. Dover books on engineering. Dover Publ, Mineola NY, 2. ed edition, 2008.
- [4] Z. Qiu, M. Santillo, M. Jankovic, and J. Sun. Composite adaptive internal model control and its application to boost pressure control of a turbocharged gasoline engine. *IEEE Transactions on Control Systems Technology*, 23(6):2306–2315, 2015.
- [5] P. Moulin, J. Chauvin, and B. Youssef. Modelling and control of the air system of a turbocharged gasoline engine. *IFAC Proceedings Volumes*, 41(2):8487–8494, 2008.
- [6] Z. Qiu, J. Sun, M. Jankovic, and M. Santillo. Nonlinear internal model controller design for wastegate control of a turbocharged gasoline engine. *Control Engineering Practice*, 46:105–114, 2016.
- [7] P. Moulin and J. Chauvin. Analysis and control of the air system of a turbocharged gasoline engine. In *Decision and Control, 2008. 47th IEEE Conference on*, pages 5643–5649. IEEE, 2008.
- [8] A. Nguyen, M. Dambrine, and J. Lauber. Lyapunov-based robust control design for a class of switching nonlinear systems subject to input saturation: Application to engine control. *IET Control Theory & Applications*, 8(17):1789–1802, 2014.
- [9] A. Nguyen, J. Lauber, and M. Dambrine. Multi-objective control design for turbocharged spark ignited air system: A switching Takagi-Sugeno model approach. In *American Control Conference (ACC), 2013*, pages 2866–2871. IEEE, 2013.
- [10] A. Nguyen, J. Lauber, and M. Dambrine. Robust  $\mathcal{H}_\infty$  control design for switching uncertain system: Application for turbocharged gasoline air system control. In *Decision and Control (CDC), 2012 IEEE 51st Annual Conference on*, pages 4265–4270. IEEE, 2012.
- [11] T. Albin, D. Ritter, D. Abel, N. Liberda, R. Quirynen, and M. Diehl. Nonlinear MPC for a two-stage turbocharged gasoline engine airpath. In *Decision and Control (CDC), 2015 IEEE 54th Annual Conference on*, pages 849–856. IEEE, 2015.
- [12] T. Albin, D. Ritter, N. Liberda, and D. Abel. Boost pressure control strategy to account for transient behavior and pumping losses in a two-stage turbocharged air path concept. *Energies*, 9(7):530, 2016.
- [13] A. Kominek, H. Werner, M. Garwon, and M. Schultalbers. Identification of low-complexity LPV input–output models for control of a turbocharged combustion engine. In *Control of Linear Parameter Varying Systems with Applications*, pages 445–460. Springer, 2012.
- [14] Lino Guzzella and Christopher Onder. *Introduction to modeling and control of internal combustion engine systems*. Springer Science & Business Media, 2009.
- [15] R Isermann. *Engine modeling and control: Modeling and electronic management of internal combustion engines*. Springer, 08 2013. doi: 10.1007/978-3-642-39934-3.
- [16] Andreas Sidorow. *Model-based Fault Diagnosis of the Air and Turbocharger System of Diesel Engines*. VDI-Verlag GmbH, 2014.

- [17] R. Sharma, D. Nesić, and C. Manzis. Model reduction of turbocharged (TC) spark ignition (SI) engines. *IEEE Transactions on Control Systems Technology*, 19(2):297–310, 2011.
- [18] A. Y. Karnik, J. H. Buckland, and J. S. Freudenberg. Electronic throttle and wastegate control for turbocharged gasoline engines. In *American Control Conference, 2005. Proceedings of the 2005*, pages 4434–4439. IEEE, 2005.
- [19] P. Gorzelic, E. Hellström, A. Stefanopoulou, L. Jiang, and S. Gopinath. A coordinated approach for throttle and wastegate control in turbocharged spark ignition engines. In *Control and Decision Conference (CCDC), 2012 24th Chinese*, pages 1524–1529. IEEE, 2012.
- [20] E. G. Gilbert, I. Kolmanovsky, and K. T. Tan. Discrete-time reference governors and the nonlinear control of systems with state and control constraints. *International Journal of Robust and Nonlinear Control*, 5(5):487–504, 1995. ISSN 1099-1239.
- [21] J.C. Doyle, K. Glover, P.P. Khargonekar, and B.A. Francis. State-space solutions to standard  $\mathcal{H}_2$  and  $\mathcal{H}_\infty$  control problems. *IEEE Trans. Aut. Contr.*, 34:831 – 847, 1989.
- [22] K. Zhou, J.C. Doyle, and K. Glover. *Robust And Optimal Control*. Prentice Hall, 1995.
- [23] P. Gahinet and P. Apkarian. An LMI-based parametrization of all controllers with applications. *Proceedings of the IEEE Conference on Decision and Control*, 1:656 – 661 vol.1, 12 1993.
- [24] S. Boyd, L. El Ghaoui, E. Feron, and V. Balakrishnan. *Linear Matrix Inequalities in System and Control Theory*. SIAM Studies in Applied Mathematics. SIAM, 1994.
- [25] G.E. Dullerud and F.G. Paganini. *A Course in Robust Control Theory a convex Approach*. Springer, 2005.
- [26] P. Apkarian and D. Noll. Nonsmooth  $\mathcal{H}_\infty$  synthesis. *IEEE Transactions on Automatic Control*, 51(1):71–86, 2006.
- [27] F. H. Clarke. Nonsmooth analysis and optimization. In *Proceedings of the international congress of mathematicians*, volume 5, pages 847–853. Citeseer, 1983.
- [28] F. H. Clarke. *Optimization and nonsmooth analysis*, volume 5. Siam, 1990.
- [29] P. Gahinet and P. Apkarian. Decentralized and fixed-structure  $\mathcal{H}_\infty$  control in MATLAB. In *Decision and Control and European Control Conference (CDC-ECC), 2011 50th IEEE Conference on*, pages 8205–8210. IEEE, 2011.
- [30] P. Gahinet and P. Apkarian. Structured  $\mathcal{H}_\infty$  synthesis in MATLAB. *IFAC Proceedings Volumes*, 44(1):1435–1440, 2011. ISSN 1474-6670. doi: 10.3182/20110828-6-IT-1002.00708.
- [31] R. Isermann and M. Münchhof. *Identification of dynamic systems: An introduction with applications*. Springer-Verlag, Heidelberg, 2011.
- [32] H. Bohn, C. et al. Unbehauen. *Identifikation dynamischer Systeme: Methoden zur experimentellen Modellbildung aus Messdaten*. Springer Vieweg, Wiesbaden, 2016.
- [33] L. Ljung. *System identification: Theory for the user*. Prentice Hall PTR, 2. ed. edition, 2012.
- [34] R. Pintelon and J. Schoukens. *System identification: A frequency domain approach*. MATLAB examples. Wiley IEEE Press and IEEE Xplore, Hoboken, NJ and Piscataway, NJ and Piscataway, New Jersey, second edition edition, 2012.
- [35] J. Raisch and E. D. Gilles. Reglerentwurf mittels  $\mathcal{H}_\infty$ -Minimierung - Eine Einführung Teil 1. *at - Automatisierungstechnik*, 40(Nr. 3):S. 84 – 92, 1992.
- [36] J. Raisch and E. D. Gilles. Reglerentwurf mittels  $\mathcal{H}_\infty$ -Minimierung - Eine Einführung Teil 2. *at - Automatisierungstechnik*, 40(Nr. 4):S. 123 – 131, 1992.
- [37] J. Raisch. *Mehrgrößenregelung im Frequenzbereich*. R. Oldenbourg Verlag München Wien, 1994.
- [38] P. Apkarian and D. Noll. Nonsmooth optimization for multidisk  $\mathcal{H}_\infty$  synthesis. *European Journal of Control*, 12 (3):229–244, 2006. ISSN 0947-3580.
- [39] F. H. Clarke, Yu. S. Ledyaev, R. J. Stern, and P. R. Wolenski. *Nonsmooth Analysis and Control Theory*. Springer-Verlag, Berlin, Heidelberg, 1998.

# Automated design of structured gain-scheduling oil pressure controllers by modern synthesis methods

**Fabian Hundertmark, Prof. Dr.-Ing Martin Grotjahn,**  
Hochschule Hannover

## 1 Zusammenfassung

In diesem Beitrag wird ein neuartiger systematischer Ansatz für das Design einer Gain-Scheduling-Regelung des Öldrucksystems von Verbrennungsmotoren vorgestellt. Hierfür werden optimale lineare zeitinvariante Regler für gegebene Arbeitspunkte entworfen und ihre charakteristischen Eigenschaften interpoliert. Ein Optimierungsalgorithmus findet für eine vorgegebene lineare Reglerstruktur mit fester Ordnung und zwei Freiheitsgraden optimale Parameter. Zur Lösung des Optimierungsproblems werden für verschiedene Übertragungsfunktionen des geschlossenen Regelkreises Beschränkungen der  $\mathcal{H}_\infty$ -Norm vorgegeben. Die Anforderungen sind für alle Arbeitspunkte identisch. Für den Gain-Scheduling-Ansatz wird keine Überlagerung der Ausgangsgrößen der linearen Regler gewählt, wie es sonst häufig üblich ist. Stattdessen werden die Pol- und Nullstellen des Gain-Scheduling-Reglers aus einem funktionalen Zusammenhang der linearen Regelkreise in Abhängigkeit der Scheduling-Variable berechnet. Der resultierende Gain-Scheduling-Regler zeigt daher unabhängig von einem der ursprünglichen Arbeitspunkte das eingestellte Verhalten der linearen Regler. Eine solche von der Nichtlinearität der Stecke unabhängige Regelung ist leistungsfähiger als konventionelle Öldruckregelungen, die aus Gründen der Robustheit zu hohe Sollöldrücke verwenden. Daraus resultiert eine Effizienzsteigerung des Öldrucksystems, die maßgeblich zur Kraftstoffeinsparung beitragen kann.

## 2 abstract

This paper presents a new systematic approach for the design of a gain-scheduling-control system for the oil pressure system of internal combustion engines. Therefore, optimal linear time invariant controller are designed at given operating points and their characteristics are interpolated by an analytical function. An optimization algorithm finds optimal parameters for a given linear controller structure with a fixed order and two degrees of freedom. To solve the optimization problem, constraints in the  $\mathcal{H}_\infty$ -norm are given for six different transfer functions of the closed loop. The same restrictions are applied for all operating points. For the gain-scheduling-approach, no classical superimposition of the output variables of the linear controllers is selected, as is often the case with gain-scheduling-controllers. Instead, the poles and zeros of the gain-scheduling-controller are functionally calculated from the linear control loops depending

on the scheduling variable. Therefore the resulting gain-scheduling-controller shows the set behaviour of the linear controllers independently of the original operating points. A control system that is independent of the nonlinearity of the route is more efficient than conventional oil pressure control systems that use too high target oil pressures for robustness reasons. This results in increased efficiency of the oil pressure system, which can make a significant contribution to fuel savings.

### 3 Introduction

In combustion engines, oil is primarily used for lubrication and cooling of valves but also used for powering hydraulic actuators, e.g. the inlet and outtake valves. In order to guarantee sufficient oil flow and to supply all parts of the engine with lubricating oil. A defined oil pressure specified for each operating point is required [14] [6], where in the presented case the operating point is defined by the engine speed. An oil pressure controller is used to provide the required oil pressure. Good oil pressure control can increase the service life of actuators and valves as well as the efficiency of the combustion engine. An efficiently running combustion engine consumes less fuel. Usually, the oil pressure in the oil circuit of combustion engines is controlled by a single-stage or two-stage mechanical control system with constant pressure levels. With such a control, the oil pressure is above the demanded pressure for each engine speed. This conversion results in a power consumption of the oil pump higher than necessary. An oil pressure control that can also control the minimum required oil pressure would therefore often lead to lower power consumption [6]. Thus, the overall efficiency of the vehicle engine can be increased and fuel consumption reduced [7]. The controlled oil pressure system depends nonlinearly on the engine speed. For this reason, a controller concept that takes nonlinearities into account and allows robustness as a criterion is more efficient than a controller whose robustness is only guaranteed by inefficient steps.

In order to control a nonlinear system over its entire operation range, different methods are available, e.g. nonlinear control, LPV control or gain-scheduling (GS). The first two require a complex model, while the last method uses Linear Time-Invariant models (LTI) for different operating points. For the third method, linear controllers are designed at operating points, where the operating points can be nonlinearly dependent on the scheduling variable.

$\mathcal{H}_\infty$ - or  $\mathcal{H}_2$ -control methods are state of the art for linear control design. However, with classic  $\mathcal{H}_\infty$ - or  $\mathcal{H}_2$ -control design methods the order of the synthesized controller has the same order as the generalized plant model. This often leads to controllers of high order. Structured, norm-optimized controller synthesis methods provide remedy [2] [4] [5] [3]. Order reduction can be applied to the controllers. Finding parameters for controller structures with limited order is now possible. At the same time, a larger number of requirements can be placed on the closed control loop without increasing the controller order. Whether all requirements can be met at the same time must still be ensured. Such a synthesis method shall be used in this article to find parameters for linear controllers. Loop shaping is performed for various transfer functions of the closed loop system. The requirements formulated in the loop shaping can be attributed to quality criteria of the control system. Thus, robustness, performance, disturbance suppression and noise reduction of the controlled variable are formulated as a direct specification for a linear

closed-loop control loop. The aim is to calculate one GS-controller from the linear controllers depending on the operating point. There is no classical GS approach. There is rather a number of approaches in which linear controllers are superimposed at operating points to control a nonlinear system depending on the scheduling variable [11].

This paper introduces a GS-controller design approach in whose poles and zeros are a function on the scheduling variable. The basis for this are working-point-dependent linear controllers, which are set according to criteria in the closed control loop in the  $\mathcal{H}_\infty$ -norm.

Structure of the paper is as follows. First, the system of the plant to be controlled is introduced. Basic properties of the linear operating points of the oil pressure system are presented. This is followed by the representation of the controller structure that is to be parameterized for oil pressure control. Now the presentation of the optimization problem for finding suitable parameters follows. Subsequently, the requirements for the closed control loop necessary for this are presented. The found linear control loops are then evaluated. Now the composition of the GS-controller is described based on the linear operating point dependent controllers. Now the results of a simulation of the GS-controller are presented. Finally, a summary of the results is given.

#### 4 The oil pressure system in the vehicle

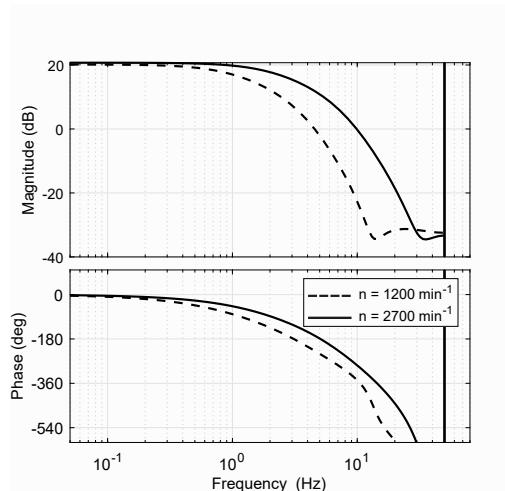


Fig. 1: Bode diagram of the time-discrete transfer functions of the oil pressure system for two ( $i = 1, 6$ ) different operating points of the engine speed  $n$

The oil pressure control in vehicles ensures that the pressure in the oil circuit is appropriate. The oil pressure demand depends on engine speed and oil temperature [10]. The aim of this

work is to design an oil pressure control system that continuously regulates the oil pressure over the entire engine speed range rather than at certain pressure levels. For this purpose, a electronically controllable oil pump is used as actuator. The oil pump is a radial pump with variable eccentricity. The pump is driven by the crankshaft. The oil filling of a control volume, which works against a spring, reduces the eccentricity. The oil pump is controlled by a pulse width modulated voltage. This voltage is the input signal of the oil pressure system. The controlled variable is the oil pressure measured in the main oil gallery. Local time-discrete models identified in advance are the basis for the controller design. The order of the model transfer functions was determined approximating the measured input and output behaviour of the real system. These models are considered as given for this work.

The identified models  $G_i$  have two zeros and three poles, as well as a delay time of 20 ms. The system's sampling time is 10 ms.

$$G_i(z) = z^{-2} \frac{b_{i1}z^{-1} + b_{i2}z^{-2} + b_{i3}z^{-3}}{1 - a_{i1}z^{-1} + a_{i2}z^{-2} + a_{i3}z^{-3}}. \quad (1)$$

The model was identified at six ( $i = 1 \dots 6$ ) operating points. The operating points differ by the constant engine speed  $n$  in each case. The difference between the operating points is constant  $\delta n = 300 \text{ min}^{-1}$ . Fig. 1 shows bode plots of the transfer functions at two different operating points. The controlled systems not shown here are in the frequency range between the systems shown. The delay is assumed to be the same for all operating points. But in reality this is not the case. Thus the deviation from the assumed fixed delay is approximated by non-minimal phase (first order Padé Approximation) in the identification.

## 5 Control Structure

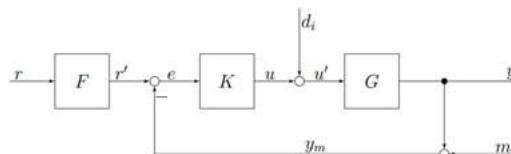


Fig. 2: Two degrees of freedom control circuit with controller  $K$  and pre-filter  $F$

The controller structure, consists of a feedback controller, denoted as controller in the following, and a feedforward controller, denoted as pre-filter see in Fig. 2. The structure with two degrees of freedom is shown in the following, the reference signal is denoted by  $r$ , the output variable of the controller by  $u$  and the controlled by  $y$ .  $G$  is a LTI model. The plant model input  $u'$  is the sum of  $u$  and a disturbance  $d_i$ . The control error  $e$  leads to the controller  $K$ . The order of controller and pre-filter was initially unspecified. Based on the results, it is later set to three for pre-filter  $F$  and controller  $K$ . The order of the structures is chosen so that the closed control loops achieve a comparable result in the time domain for all operating points. In addition to the

controller order and structure, a fixed integrator has been defined. The controlled signal  $y$  is corrupted by additive measurement noise  $m$  resulting in the measured control variable  $y_m$ . The control design should be discrete in time to allow later implementation in the engine control unit (ECU).

## 6 Structured norm optimal controller design

For the design of the operating point-dependent linear controllers, we suggest a method for the synthesis of structured norm-optimal controllers. This method was introduced in [2] [4] and the optimization algorithm is available in the MATLAB Toolbox "Control System Tuner". Requirements of the closed loop behaviour are formulated. The freely adjustable controller parameters (tuning parameters, optimization variables) respectively are collected in a vector  $x$ . These parameters can be limited, so that  $x \in X \subset \mathbb{R}^{n_0}$  and  $X$  is the subset of the acceptable values. The synthesized controller  $K$  comes from the set of all structure-restricted controllers  $\mathcal{K}$ . This leads to a controller design in which the optimization problem

$$\min_{x \in X \subset \mathbb{R}^{n_0}} \max_{j=1 \dots n_A} \{f_j(K(x))\} \quad (2)$$

in consideration of  $K \in \mathcal{K}$  is solved [2]. With the optimization method, parameters  $x$  of the controller structure are found which means a minimum of the quality criterion above the maximum of all the requirements  $f_j$  formulated in the  $\mathcal{H}_\infty$ -norm. The number of requirements  $n_A$  is not limited. Unlike the classic  $\mathcal{H}_\infty$ -control design, the controller structure and order can be determined independently of the number of requirements  $n_A$ . Requirements  $f_j$  are given uniformly in the form

$$f_j(K(x)) = \left\| \frac{1}{W_j(j\omega)} G_{fj}(j\omega, x) \right\|_\infty. \quad (3)$$

Where  $G_{fj}(j\omega, x)$  is the transfer function to be weighted and  $W_j(j\omega)^{-1}$  is the formulated weight. The optimization problem to be solved is generally non-smooth and not convex [5]. This solution of the optimization problem is a generalization of the gradient method for problems that can not be differentiated in the classical sense, but which are at least sub-differentiated [8] [9]. However, the algorithms used for the solution only guarantee convergence to a local minimum, but no convergence to a global minimum [12].

## 7 Requirements

For the linear operating point-dependent controllers, weights are designed for transfer functions of the extended control loop with pre-filter. The requirements are made on the close-control loop, also some requirements have to be translated into the frequency domain. Quality criteria for control can be derived from each of these transfer functions. These quality criteria are performance, maximization of stability reserve, suppression of noise of the process signal  $m$  and suppressing disturbing influences  $d_i$ . In order to obtain similar time behaviour, the Kriterien to the transfer functions  $G_f$  of the closed control loop are the same at all operating points. The definitions of the weighted transfer functions are shown in Tab. 1.

Table 1: All requirements for linear control design

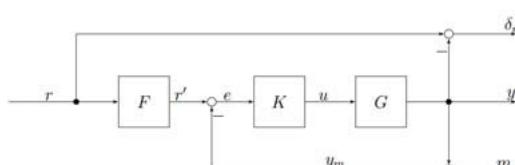
Requirement	$G_f$
$f_1$	$S(j\omega) = \frac{e}{r'} = \frac{1}{1 + G(j\omega)K(j\omega)}$
$f_2$	$KS(j\omega) = \frac{u}{r'} = \frac{K(j\omega)}{1 + G(j\omega)K(j\omega)}$
$f_3$	$SG(j\omega) = \frac{y}{u'} = \frac{G(j\omega)}{1 + G(j\omega)K(j\omega)}$
$f_4$	$FKS(j\omega) = \frac{u}{r} = \frac{F(j\omega)K(j\omega)}{1 + G(j\omega)K(j\omega)}$
$f_5$	$FT(j\omega) - 1 = \frac{\delta_r}{r} = \frac{F(j\omega)K(j\omega)G(j\omega)}{1 + G(j\omega)K(j\omega)} - 1$

As an example of a weight, the transfer function of the sensitivity

$$S(j\omega) = \frac{1}{1 + G(j\omega) \cdot K(j\omega)} \quad (4)$$

is considered in the following. Requirements for the control loop that can be set via the sensitivity function are robustness and performance. Robustness is a crucial criterion for the control design. System parameters can often only be estimated or represented by linearization at the operating point. The resulting error increases with increasing distance to the point of linearization. A robust control system can stabilize the closed control loop within given limits even if the system parameters deviate. To assess the robustness, the maximum of the sensitivity

$$M_S = \max_{\omega} |S(j\omega)| = \|S(j\omega)\|_{\infty} \quad (5)$$

Fig. 3: Block diagram of the transfer function  $FT - 1(j\omega)$

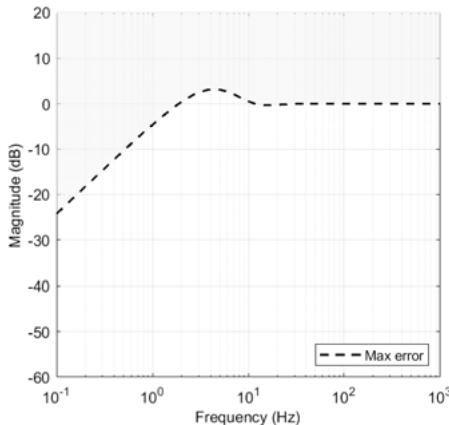


Fig. 4: Frequency response of Magnitude of the fives requirement barrier

can be used, since the smallest distance to the critical point  $-1$  is  $M_S^{-1}$  [13].  $M_S$  should be small ( $< 6$  dB) to ensure robustness against system uncertainties.

The requirement  $f_5$  is shown in Fig. 3 in a block diagram. This transfer function is described with the output control error  $\delta_r$  between  $r$  and  $y$  and the input  $r$ . The weighting of this transfer function tunes the power in relation to the change in the setpoint and its course. This requirement not only specifies the desired performance as the target, it also determines the dynamic behaviour of the controlled variable.

In order to obtain a desired behaviour in frequency domain, first we consider the behaviour in time domain. In adaption of the step response of linear control loops at the operating points, the form of the controlled variable should be that of an adapted third-order system. The course of the controlled variable is thus based on the course of the step response of the identified systems. The transfer function searched for has the form

$$G_{\text{Ref}} = e^{-s \cdot T_t} \left( \frac{1}{s \cdot T_{\text{ref}} + 1} \right)^3. \quad (7)$$

The delay  $T_t$  is identified as a fixed value during the system identification, thus it is adapted to the closed loop dynamics (to demand a behaviour that can be achieved through the closed loop). The performance can be adjusted by  $T_{\text{ref}}$ . The weighting of the transfer functions is chosen so that the behaviour of the closed loop is independent of the operating point. The time response of the GS-control via the scheduling variable should remain constant. For this reason the system can be considered as LTI.

Fig. 4 shows the frequency response of the amplitude of the upper bound of requirement  $f_5$ . In dotted the maximum of the limit is shown. After solving the optimization problem, the transfer

function of the closed control loop should not exceed the limit with any amplitude value.

## 8 Evaluation of operating point dependent controllers

There are two ways for evaluating the control structure with respect to the requirements. The quality criterion  $\gamma_j$  indicates whether the requirements are met. If value  $\gamma_j > 1$ , the requirement is not met. Once a  $\gamma_j > 1$ , the performance criterion of all other requests maybe be greater than one. For the evaluation, not only the maximum of  $\gamma_j$  is taken into account, but also all other requirements related to this maximum of  $\gamma_j$ . If once  $\gamma_j > 1$  is found, it does not necessarily mean that the parameters found by solving the optimization problem can not be used. If  $\gamma_j$  is very close to 1, this may be exceeding the limit in the uncritical range, so the solution is sufficient. Alternatively, the requirements must be adjusted until all  $\gamma_j < 1$ . This may take a very long time or lead to the restrictions being much less strict.

### 8.1 Step responses of closed loops

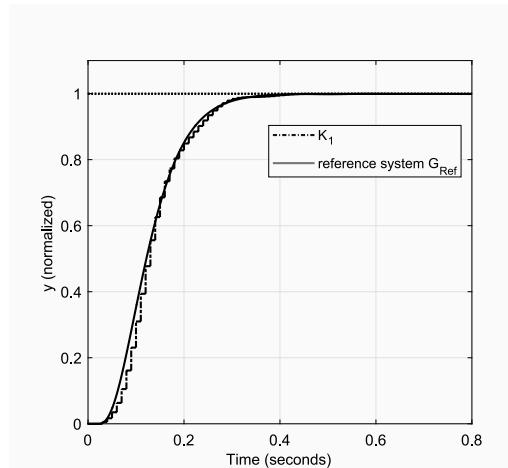


Fig. 5: Step Response of the controller at the first operating point and the reference system  $G_{\text{Ref}}$

At each operating point one LTI controller is designed. All of these controller designs have a comparable performance. The comparison to the synthesized reference behaviour for a step response at the first operating point in Fig. 5 shows that the performance target is met.

The overall goal of controller synthesis is to obtain control loops with similar performance. In Fig. 6 the resulting step responses of the closed loops at all operating points are given. By setting the same requirements, the suggested optimization approach leads to comparable time behaviour of all closed loops.

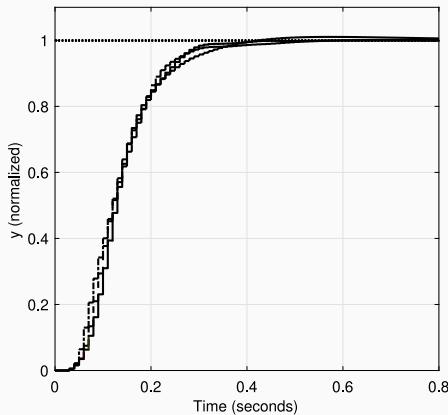


Fig. 6: Resulting closed-loop step responses for three operating points, which are quite similar (1, 3, 6; lines are arranged one above the other).

## 8.2 Frequency domain behaviour

The similarity of the found controllers can also be displayed in frequency domain. In Fig. 7, the bode plots of the controllers  $K_i$  are presented for three operating points. The controllers  $K_i$  are shifted to higher frequencies as the engine speed  $n$  increases. The course over the speed is relatively clear. The bode plots not shown are in the frequency range between the shown. This implicates that an interpolation of the poles and zeros as a function of the scheduling variable is permissible.

## 9 Synthesis of the GS-controller

In order to synthesize the GS-controller, it is not intended to superimpose the manipulated variable of the individual linear control loops [1]. This approach, known from the literature, leads to control loops whose behaviour does not correspond to the desired characteristic in the frequency domain. In this way, however, the characteristics of the poles and zeros between two operating points are not mapped. In order to better map the expected behaviour, the synthesized GS-controller should consist of a functional relationship of the poles and zeros of the linear controllers at the operating points.

For this purpose, the variation of the poles/zeros at each operating point is represented by linear functions in the complex z-plane obtained by a least-squares fitting. In Fig. 8, the representation of the controllers bode plots is shown. The controllers  $K_i$  are shown as dashed lines. Displayed with solid lines is the magnitude responses of the GS-controller. Both variants are represented at three of the original work points of the engine speed ( $n = 1200 \text{ min}^{-1}$ ,  $n =$

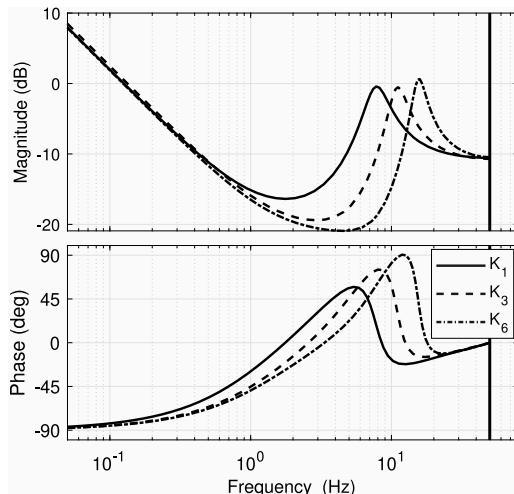


Fig. 7: Bode diagram of the synthesized controller,  $K_i$  at three ( $i = 1, 3, 6$ ) operating points of the engine speed

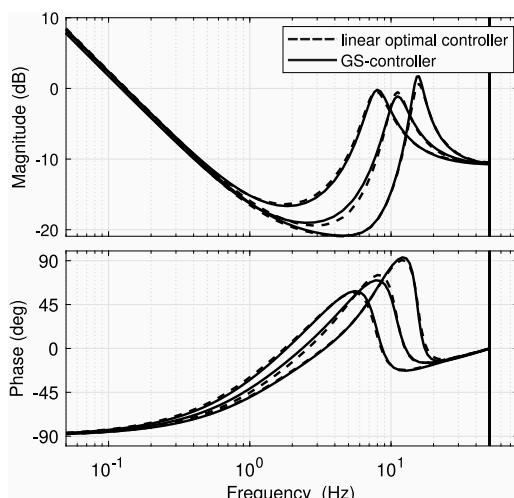


Fig. 8: Bode plot of the controllers  $K_i$  and the GS-controller  $K_{\text{gain}}$  at three ( $i = 1, 3, 6$ ) operating points of the engine speed  $n$

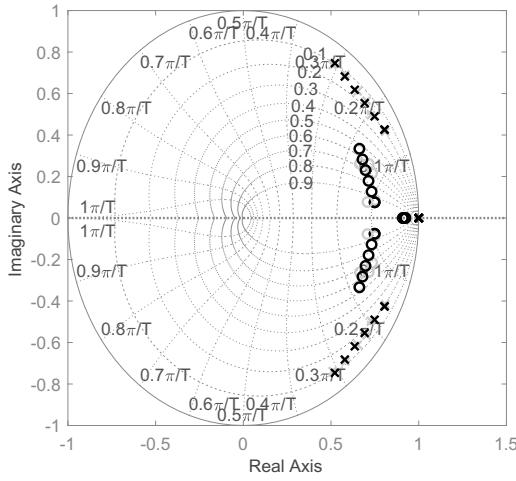


Fig. 9: Pol-zero representation of the controllers  $K_i$  in gray and the GS-controller  $K_{\text{gain}}$  in black at the original operating points

$1800 \text{ min}^{-1}, n = 2700 \text{ min}^{-1}$ ). In addition, the controller poles and zeros are compared in Fig. 9. The pole and zeros of the GS-controller changes with the scheduling variable. The linear dependence by the least squares estimation of the pole and zeros is also shown in Fig. 9. At the operating points, the poles in particular, have a small difference to the operating point-dependent controllers. The poles can be regarded as the most important characteristics, since they influence the behaviour in the frequency domain to a certain extent. It can therefore be assumed that the GS-controller can reproduce the characteristics of the original controllers very well at the operating points.

## 10 Evaluation

As no real engine has been available the evaluation is conducted by simulations. The control structure with pre-filter  $F$  and controller  $K$  are simulated with the oil pressure system shown in the Fig. 2. Controllers and pre-filters are designed as proposed in section 6. The sampling time is  $T_s = 0.01 \text{ s}$ . The oil pressure of the real system in combustion engines changes continuously, so that in the simulation the system  $G_{\text{gain}}$  is also simulated as a system whose oil pressure changes continuously. The measured controlled variable  $y_m$  is sampled by a zero-order hold.

The simulation is structured in such a way that the engine speed, i.e. the scheduling variable, can be changed continuously. Step responses of the system for different engine speeds are shown in Fig. 10. The engine speeds do not necessarily correspond to the previously selected operating points. The controller generates a comparable time behaviour of the control loop, irrespective of the engine speed. A step height of  $60 \text{ kPa}$  is given. For controlling the oil

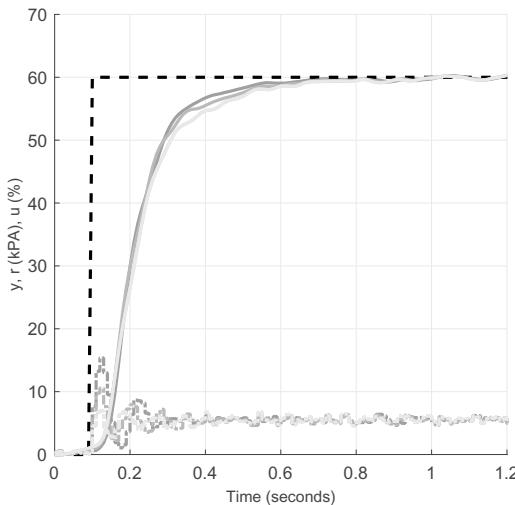


Fig. 10: Simulation results of GS-control for step responses at three different engine speeds (solid line in gray scales for the controlled variable  $y$ , dotted lines in gray scales for the actuating variable  $u$ , dashed black line for the reference variable)

pressure near the demand oil pressure, no jumps occur. Only if the motor is switched on a setpoint variable of approx. 120 kPa will be specified in the form of a step [6]. The GS-controller is designed for an average step height of 60 kPa. However, even for a higher jump of  $r = 120$  kPa, the actuating variable will not be limited. Fig. 10 shows the controlled variable  $y$  of the  $G_{\text{gain}}$  plant model. The scheduling variable  $n$  is changed for four jumps in  $500 \text{ min}^{-1}$  steps, starting with  $n = 1200 \text{ min}^{-1}$ . The graph of  $y$  is shown in various shades of grey. The gradations from dark to light represent the step response of the control loop at different engine speeds. For a smaller scheduling variable, the respective color is darker. Fig. 10 also presents actuating variable in the same greyscale gradations, but dashed.

The Fig. 11 shows the resulting disturbance behaviour (disturbance step high  $d_i = 3\%$ ). The controlled variable follows the reference variable with a value of  $r = y = 60$  kPa at the time of the disturbance step at  $T = 1.5$  s. The error is compensated for all operating points after approximated time of 0.8 s. The simulation displays the expected results. The GS-controller exhibits constant time behaviour at all simulated operating points. The operating points are located between the original operating points. Although the GS-controller is not designed for these operating points, it shows the desired behaviour independently of the scheduling variable. A prototype test with a combustion engine in a vehicle is still pending.

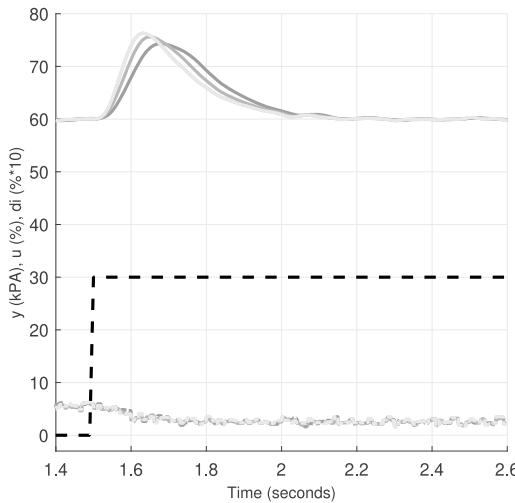


Fig. 11: Simulation results of the GS-control for disturbance steps at different engine speeds (solid line in gray scales for the controlled variable  $y$ , dotted lines in gray scales for the actuating variable  $u$ , dashed black line for the disturbance variable  $d_i$ )

## 11 Conclusions

Nowadays, the oil pressure in automotive vehicles is controlled by means of a stepped setpoint input. To ensure robustness, usually the pressure stages are far above the required minimum oil pressure. The oil pressure is often chosen so high because the control cannot keep the oil pressure stable enough above the minimum pressure. The control of the oil pressure higher than the minimum oil pressure is inefficient and requires more energy. By considering robustness in the controller design, the GS-control presented in this article can control the nonlinear oil pressure path close to the required minimum oil pressure. This type of control not only saves fuel, it also reduces wear in the valves and the oil pump.

Linear models of the oil pressure range, depending on the engine speed, form the basis for linear structurally limited optimum controllers. The parameters are designed by solving an optimization problem while limiting the  $\mathcal{H}_\infty$ -norm transfer functions of the closed-loop system. The same requirements are formulated for all operating points in order to obtain a similar behaviour. The dependency on the scheduling variable of the synthesized controllers also becomes clear in the frequency domain. Since the GS-controller is also intended to control the system between the originally identified operating points, the characteristics of the linear controllers are made functionally dependent on the scheduling variable. The composite GS-controller can now be combined to one linear controller for each value of the scheduling variable. The dynamics of this controller remains similar for varying values of the scheduling variable. The resulting behaviour is evaluated by simulation experiments. The results prove the capacity of the sug-

gested controller design approach. In the simulation, the controller also shows behaviour that is largely independent of the operating point. These results at the nonlinear system are achieved, even though only requirements for a linear controller design have been made.

## Literatur

- [1] J. Adamy. *Nichtlineare Systeme und Regelungen*. Research (Wiesbaden, Germany). Springer Berlin Heidelberg, 2018.
- [2] P. Apkarian. Tuning controllers against multiple design requirements. In *System Theory, Control and Computing (ICSTCC), 2012 16th International Conference on*, pages 1–6. IEEE, 2012.
- [3] P. Apkarian, M. N. Dao, and D. Noll. Parametric robust structured control design. *IEEE Transactions on automatic Control*, 60(7):1857–1869, 2015.
- [4] P. Apkarian and D. Noll. Nonsmooth  $\mathcal{H}_\infty$  synthesis. *IEEE Transactions on Automatic Control*, 51(1):71–86, 2006.
- [5] P. Apkarian and D. Noll. Nonsmooth optimization for multidisk  $\mathcal{H}_\infty$  synthesis. *European Journal of Control*, 12(3):229–244, 2006.
- [6] M. Berg. *Ölkreislauf von Verbrennungsmotoren*. Number Bd. 3 in Fachbuch/ Haus der Technik. expert-Verlag, 2009.
- [7] H. Braess and U. Seiffert. *Vieweg Handbuch Kraftfahrzeugtechnik*. ATZ/MTZ-Fachbuch. Vieweg+Teubner Verlag, 2011.
- [8] F. H. Clarke. *Optimization and nonsmooth analysis*, volume 5. Siam, 1990.
- [9] F. H. Clarke, Y. S. Ledyaev, R. J. Stern, and P. R. Wolenski. *Nonsmooth analysis and control theory*, volume 178. Springer Science & Business Media, 2008.
- [10] R. Isermann. Engine modeling and control. *Berlin: Springer Berlin Heidelberg*, 2014.
- [11] G. J. L. Naus. Gain scheduling robust design and automated tuning of automotive controllers. University of Technology, Eindhoven, 2009.
- [12] D. Noll. Cutting plane oracles to minimize non-smooth non-convex functions. *Set-Valued and Variational Analysis*, 18(3-4):531–568, 2010.
- [13] S. Skogestad and I. Postlethwaite. *Multivariable feedback control: analysis and design*, volume 2. Wiley New York, 2007.
- [14] R. van Basshuysen and F. Schäfer. *Handbuch Verbrennungsmotor: Grundlagen, Komponenten, Systeme, Perspektiven*. ATZ/MTZ-Fachbuch. Springer Fachmedien Wiesbaden, 2017.

# **Zusammenspiel von optimierungsbasierter Lastpunktbestimmung mit regel- und optimierungsbasierten elektrischen Fahrentscheidungen in Plug-In-Hybrid-Fahrzeugen**

**M.Sc. Roland Schmid, Dr. -Ing. Johannes Bürger,**

BMW Group, München;

**Prof. Dr.-Ing. Naim Bajcinca,**

Technische Universität Kaiserslautern, Kaiserslautern

## **Zusammenfassung**

Die vorliegende Arbeit präsentiert den Vergleich zweier globaler, auf Vorausschau-Informationen basierenden Betriebsstrategien für Plug-In-Hybrid-Fahrzeuge. Der Hauptfokus der Arbeit liegt hierbei auf dem Vergleich einer regelbasierten und einer optimierungsbasierten elektrischen Fahrentscheidung. Hierfür wird zuerst eine regelbasierte elektrische Fahrentscheidung mit einer auf dem Minimums Prinzip nach Pontryagin basierenden Lastpunktbestimmung kombiniert. Im Anschluss daran wird die präsentierte, regelbasierte Betriebsstrategie mit einer optimierungsbasierten, konsistent auf dem Minimums Prinzip nach Pontryagin basierenden Betriebsstrategie verglichen. Abschließend wird ein applizierbarer Strafterm in die optimierungsbasierte Betriebsstrategie integriert um das resultierende hochfrequente Motor-Start-Stopp Verhalten zu reduzieren.

## **Abstract**

This paper presents a comparison of two global energy management strategies of plug-in-hybrid electric vehicles which are based on trip preview information. Thereby the main focus lies on the comparison of a rule based and an optimization based electric drive decision. First a rule based electric drive decision is presented which is combined with an optimization based load-point-shift based on Pontryagin's Minimums principle. Subsequently an optimization based energy management strategy is presented which is consistently based on Pontryagin's Minimus Principle. Finally a tuneable penalty term is introduced in order to reduce the resulting high engine start-stop frequencies.

## **1. Einleitung**

Angekurbelt durch politische und soziale Diskussionen, steigende Rohstoffpreise und erhöhte Emissionswerte werden derzeit immer mehr Lösungen für effiziente, alternative und umweltfreundliche Antriebskonzepte entwickelt. In diesem Zusammenhang erfreuen sich besonders Plug-In-Hybrid-Fahrzeuge (Plug-in-Hybrid Electric Vehicles – PHEV) einer rasch zunehmenden Beliebtheit. Dies kann vor allem durch die in PHEV verwendete Kombination

eines Elektromotors mit einem Verbrennungsmotor erklärt werden, da diese benutzt werden kann um den Kraftstoffverbrauch und den Emissionsausstoß des Fahrzeugs deutlich zu senken. In diesem Zusammenhang spielt die Betriebsstrategie des PHEV eine zentrale Rolle, da diese die durch die Antriebsarchitektur des Fahrzeugs entstehenden Freiheitsgrade (Lastpunktverschiebung und elektrische Fahrentscheidung) optimal einstellt. Betriebsstrategien für Hybridfahrzeuge lassen sich, wie in Abbildung 1 gezeigt, in einem ersten Schritt in lokale und globale Ansätze unterteilen.

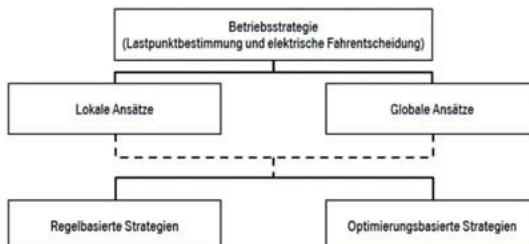


Abbildung 1: Gruppierungen verschiedener Betriebsstrategien.

Lokale Betriebsstrategien betrachten jeweils nur das Fahrzeugverhalten des aktuellen Zeitschritts um die Freiheitsgrade des Systems einzustellen. Dadurch kann eine recheneffiziente und intuitive Einstellung der Freiheitsgrade erfolgen. Durch eine mangelnde Berücksichtigung des zukünftigen Fahrzeugverhaltens kann jedoch ein, über den gesamten Reisehorizont gesehener, ineffizienter Betrieb des Fahrzeugs erfolgen. Globale Betriebsstrategien hingegen betrachten das Fahrzeugverhalten über die gesamte Reise hinweg und stellen somit basierend auf dem Wissen über die zukünftige Reise die Freiheitsgrade des Systems in jedem Zeitpunkt effizient ein. Somit kann auf den gesamten Reisehorizont bezogen eine effizientere Einstellung der Freiheitsgrade erfolgen, wodurch das volle Potential von PHEV ausgeschöpft werden kann. Aus diesem Grund sollen in dieser Arbeit nur globale Betriebsstrategien betrachtet werden, welche basierend auf einer idealen Vorausschau (exakte Vorausschau ohne Unsicherheit) die Freiheitsgrade des PHEV einstellen. Nachgelagert kann wiederum bei globalen sowie lokalen Ansätzen in regelbasierten und optimierungsbasierten Strategien unterschieden werden. Regelbasierte Strategien, wie in [1], verwenden Regeln welche durch Zyklusbetrachtungen und/oder Knowhow des applizierenden Ingenieurs vorab definiert und eingestellt werden. Optimierungsbasierte Strategien verwenden hingegen mathematische Methoden um eine optimale Einstellung der Freiheitsgrade zu garantieren. Die am weitesten verbreiteten Methoden stellen hierbei das Minimums Prinzip nach Pontryagin (PMP) [2], [3] und die daraus abgeleitete Equivalent-Consumption-Minimization-Strategy (ECMS) [4] dar. PHEV besitzen im Unterschied zu Mild-

Hybrid-Fahrzeugen, die Möglichkeit eine elektrische Fahrentscheidung zu treffen und somit rein elektrisch angetrieben zu werden. Dadurch erhalten PHEV zusätzlich zur Lastpunktbestimmung einen weiteren Freiheitsgrad. Dieser zusätzliche Freiheitsgrad kann wiederum durch die Betriebsstrategie eingestellt werden um den Kraftstoffverbrauch des Fahrzeugs weiter zu reduzieren. Um dieses Potential möglichst optimal ausnutzen zu können, können regelbasierte oder optimierungsbasierter Betriebsstrategien eingesetzt werden. Ziel dieser Arbeit soll sein, zwei globale Betriebsstrategien für ein paralleles PHEV mit einer regelbasierten und einer optimierungsbasierter elektrischen Fahrentscheidung gegenüberzustellen und die Vor- und Nachteile der beiden Strategien hervorzuheben. Zu diesem Zweck wird die auf PMP basierende Lastpunktbestimmung mit einer auf vorab definierten Regeln basierenden elektrischen Fahrentscheidung kombiniert und mit der in [5] präsentierten, durchgehend konsistent auf PMP basierenden Bestimmung von Lastpunkt und elektrischer Fahrentscheidung verglichen. In einem weiteren Schritt wird das auftretende hohe schaltende Verhalten der elektrischen Fahrentscheidung durch Einführung eines applizierten Strafterms für einen Motorstart reduziert. Da der Fokus dieser Arbeit auf dem Vergleich der regelbasierten und optimierungsbasierter elektrischen Fahrentscheidung liegen soll, erfolgt in beiden Ansätzen eine identische, optimierungsbasierter Lastpunktbestimmung auf Basis des in [5] präsentierten analytischen Verfahrens basierend auf PMP. Das nachfolgende Dokument ist wie folgt gegliedert: Zuerst werden in Kapitel 2 die Grundlagen für eine vorausschauende Betriebsstrategie von PHEV gelegt. In Kapitel 3 wird eine auf einer regelbasierten elektrischen Fahrentscheidung basierende Betriebsstrategie vorgestellt, bevor in Kapitel 4 eine rein auf PMP basierende Betriebsstrategie eines PHEV vorgestellt wird. Anschließend wird in Kapitel 5 die auf PMP basierende Betriebsstrategie durch einen Strafterm für auftretende Motorstarts ergänzt, um ein hochfrequentes Motor-Start-Stopp-Verhalten zu vermeiden. Abschließend werden die resultierenden Ergebnisse in Kapitel 6 zusammengefasst und diskutiert.

## **2. Grundlagen einer vorausschauenden Betriebsstrategie für parallele Plug-In-Hybridfahrzeuge**

Parallele PHEV besitzen eine parallele Antriebsstruktur, bestehend aus einem Verbrennungsmotor und einem Elektromotor, welche, wie in Abbildung 2, gezeigt durch eine Kupplung miteinander verbunden sind. Durch diese parallele Antriebsstruktur besitzen parallele PHEV gegenüber konventionellen Antriebsstrukturen den Vorteil, dass sie rein verbrennungsmotorisch, rein elektrisch oder durch eine Kombination von beidem angetrieben werden können. Darüber hinaus ist es durch Rekuperation in Verzögerungsphasen oder durch eine Lastpunktanhebung möglich, die an Bord verbaute Batterie durch die zusätzlich zur Verfügung stehende Energie zu laden.

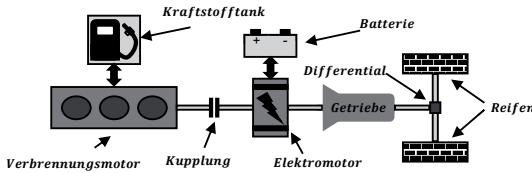


Abbildung 3: Systemtypische Struktur eines parallelen PHEV.

Um eine globale Betriebsstrategie von PHEV implementieren zu können, muss dieses Systemverhalten durch ein geeignetes Modell beschrieben werden. Zu diesem Zweck wird das in Abbildung 3 dargestellte Systemmodell verwendet, welches die Leistungsverzweigung des betrachteten parallelen PHEV darstellt. Dabei wird die Verteilung der vom Fahrer angeforderten Leistung  $P_{req}$  auf die vom Elektromotor gestellte mechanische Leistung  $P_e$  und die vom Verbrennungsmotor gestellte Leistung  $P_c$  dargestellt als

$$P_{req} = P_e + P_c. \quad (1)$$

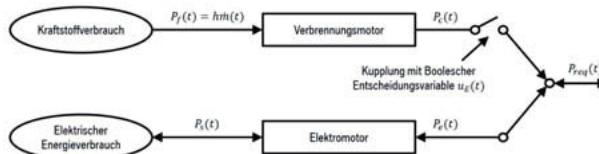


Abbildung 2: Verwendetes Systemmodell des betrachteten parallelen Plug-In-Hybrid Fahrzeugs.

Hierbei wird angenommen, dass die auftretenden mechanischen Verluste des Getriebes bereits in  $P_{req}$  berücksichtigt sind. Des Weiteren wird angenommen, dass die Wahl des Ganges durch eine übergeordnete, separate Funktion des Antriebsstrangs vorgenommen wird und nicht durch die Betriebsstrategie beeinflusst wird. Somit kann die Drehzahl  $n(t)$  in Abhängigkeit des gewählten Ganges und der Fahrzeuggeschwindigkeit  $v(t)$  eindeutig bestimmt werden. Die mechanischen und elektrischen Verluste des Verbrennungsmotors und des Elektromotors werden als drehzahlabhängige Kennfelder beschrieben, welche durch ausführliche Messungen an Motorprüfständen ermittelt werden können. Dadurch können die chemische Leistung  $P_f = hm(t)$ , welche aus der Verbrennung von Kraftstoff resultiert ( $h$  = unteren Heizwertes des Kraftstoffs,  $m(t)$  = momentaner Kraftstoffmassenstrom) und die elektrische Leistung  $P_s$ , welche aus der Batterie entladen oder in die Batterie geladen wird, über die Funktionen  $f(\cdot)$  und  $g(\cdot)$  beschrieben werden.  $f(\cdot)$  und  $g(\cdot)$  sind dabei drehzahlabhängige Funktionen der Kurbelwellen-Drehzahl und den mechanischen Leistungen des Verbrennungsmotors bzw. des E-Motors und können z.B. über eine quadratische Näherung entsprechender Komponenten-Kennfelder bestimmt werden:

$$P_f(t) = u_E(t)f(P_c(t), n(t)) \quad (2)$$

$$P_s(t) = g(P_e(t), n(t)). \quad (3)$$

Die boolesche Entscheidungsvariable  $u_E(t) \in \{0,1\}$  repräsentiert hierbei den aktuellen Zustand des Verbrennungsmotors und der Kupplung ( $u_E(t) = 0$  - Verbrennungsmotor ist aus und die Kupplung ist geöffnet,  $u_E(t) = 1$  - Verbrennungsmotor ist an und die Kupplung ist geschlossen). Somit lässt sich die zeitliche Änderung des Energiegehalts der Batterie  $E(t)$  durch die Beziehung

$$\dot{E}(t) = -P_s(t) \quad (4)$$

beschreiben. Zusätzlich zur Wahl einer geeigneten Systemmodellierung muss als Grundlage für eine globale Betriebsstrategie das zukünftige Fahrzeugverhalten über den gesamten vorausliegenden Reisehorizont vorab bekannt sein. Um eine möglichst genaue Prädiktion des zukünftigen Fahrzeugverhaltens ermöglichen zu können, können verschiedenste Informationsquellen wie Kartendaten, Fahrertypanalysen oder Fahrzeugfrottendaten berücksichtigt werden. Da die Prädiktion des in der Zukunft liegenden Fahrzeugverhaltens jedoch nicht im Fokus dieser Arbeit liegt, soll in dieser Arbeit eine optimale Prädiktion des vorausliegenden Fahrzeugverhaltens, also eine exakte, nicht mit Unsicherheit behaftete Prädiktion angenommen werden.

Im Folgenden soll nun basierend auf der eben präsentierten Systemmodellierung und einer exakten Vorausschau eine globale Betriebsstrategie mit einer regelbasierten elektrischen Fahrentscheidung und einer auf PMP basierenden Lastpunktbestimmung mit einer globalen, konsistent auf PMP basierenden Betriebsstrategie verglichen werden.

### 3. Globale Betriebsstrategie mit einer regelbasierten elektrischen Fahrentscheidung

Die in dieser Arbeit präsentierte, globale Betriebsstrategie mit einer regelbasierten elektrischen Fahrentscheidung verwendet die in Abbildung 4 dargestellte, zweistufige Struktur. Hierbei stellt

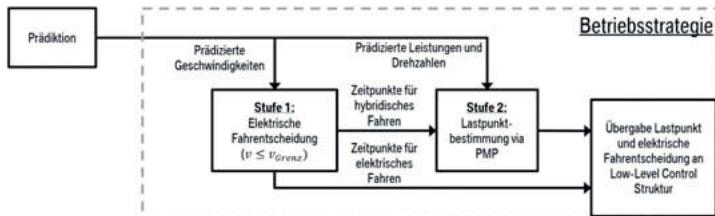


Abbildung 4: Struktur der betrachteten regelbasierten Betriebsstrategie.

die bereits erwähnte Prädiktion des zukünftigen Fahrzeugverhaltens den Input der Betriebsstrategie dar. Basierend auf dem vorausliegenden, prädizierten Geschwindigkeiten, Drehzahlen und Leistungen werden in zwei aufeinander folgenden Stufen die zu stellenden

Lastpunkte und elektrischen Fahrentscheidungen für alle vorausliegenden Zeitpunkte der betrachteten Reise bestimmt. Zu diesem Zweck wird in der ersten Stufe der Betriebsstrategie eine regelbasierte, elektrische Fahrentscheidung getroffen. Hierfür soll in dieser Arbeit die in (5) definierte, auf einer vorab festgelegten Grenzgeschwindigkeit ( $v_{Grenz}$ ) basierende, Regel verwendet werden, um die elektrische Fahrentscheidung zu treffen.

$$u_E(t) = \begin{cases} 0 & (\rightarrow \text{elektrisches Fahren}) & \text{falls } v(t) \leq v_{Grenz} \\ 1 & (\rightarrow \text{hybridisches Fahren}) & \text{sonst} \end{cases} \quad (5)$$

Somit erfolgt in der ersten Stufe der Betriebsstrategie eine Unterteilung in rein elektrisch zu befahrende Zeitpunkte ( $u_E(t) = 0$ ) und hybridisch zu befahrende Zeitpunkte ( $u_E(t) = 1$ ). Anschließend ist es in einer darauffolgenden zweiten Stufe notwendig, den Lastpunkt für die verbleibenden, hybridisch zu befahrenden, Zeitpunkte zu bestimmen. Zu diesem Zweck wird das in [5] präsentierte, auf PMP basierende, analytische Verfahren für eine optimale Lastpunktbestimmung verwendet, welches den Kraftstoffverbrauch des Fahrzeugs minimiert. Hierfür wird eine Kostenfunktion

$$J = \int_0^T h \dot{m}(t) dt = \int_0^T P_f \left( P_s(t), P_{req}(t), n(t) \right) dt \quad (6)$$

definiert, welche den gesamten Kraftstoffverbrauch des Fahrzeugs zu den Zeitpunkten  $\Theta$  darstellt (Wobei  $\Theta$  die Menge der Zeitpunkte repräsentiert, zu denen hybridisch gefahren wird). Der Kraftstoffverbrauch des Fahrzeugs wird hierbei durch die chemische Leistung  $P_f(t)$  beschrieben, welche durch die in Kapitel 2 beschriebene Systemmodellierung als Funktion der als Steuergröße betrachteten Leistung  $P_s(t)$  ( $u(t) = P_s(t)$ ) dargestellt werden kann. Dieser funktionelle Zusammenhang kann für den Fall eines laufenden Verbrennungsmotors ( $u_E(t) = 1$ ), wie in [5] gezeigt, als eine quadratische Funktion des hier betrachteten Systemeingangs  $u(t) = P_s(t)$  angenähert werden:

$$P_f \left( P_s(t), P_{req}(t), n(t) \right) = \gamma_0 \left( P_{req}(t), n(t) \right) + \gamma_1 \left( P_{req}(t), n(t) \right) P_s(t) + \gamma_2 \left( P_{req}(t), n(t) \right) P_s(t)^2. \quad (7)$$

Die verwendeten Koeffizienten  $\gamma_i$  mit  $i = \{0,1,2\}$  sind hierbei von der in den jeweiligen Zeitschritten angeforderten Leistung  $P_{req}(t)$  und Drehzahl  $n(t)$  abhängig. Mithilfe der in (6) definierten Kostenfunktion kann nun das Minimums Prinzip nach Pontryagin (PMP) angewendet werden um die optimale Leistung  $P_{s,opt}(t)$  zu bestimmen, welche über die gewählte Systemmodellierung den optimalen Lastpunkt des Verbrennungsmotors definiert (vgl. (1)-(3)). Das Minimums Prinzip nach Pontryagin (vgl. [6]) sagt aus, dass ein Kandidat für eine optimale Leistung  $P_{s,opt}(t)$  gefunden ist, falls diese die definierte Hamiltonfunktion

$$H(P_s(t), P_{req}(t), n(t), \lambda(t)) = P_f(P_s(t), P_{req}(t), n(t)) - \lambda(t)P_s(t) \quad (8)$$

unter Einhaltung der folgenden Nebenbedingungen minimiert:

$$\dot{E}(t) = -P_s(t) \quad (9)$$

$$E(0) = E_{Start} \quad (10)$$

$$E(T) = E_{Ende} \quad (11)$$

$$\dot{\lambda} = -\frac{\partial H(P_s(t), P_{req}(t), n(t), \lambda(t))}{\partial E(t)}. \quad (12)$$

Hierbei stellen  $E_{Start}$  und  $E_{Ende}$  den initial und final in der Batterie enthaltenen Energieinhalt und  $\lambda(t)$  den Co-State dar. Im Folgenden wird  $\lambda(t)$  (wie in der Literatur üblich) durch  $s(t) = -\lambda(t)$  ersetzt um ein positives Vorzeichen zu erhalten. Vergleicht man die gewählte Systemmodellierung mit (12) so stellt man fest, dass in dem gegebenen Fall die Hamiltonfunktion nicht vom gewählten Systemzustand  $E(t) = x(t)$  abhängt, wodurch der Co-State konstant ist (vgl. [3]):

$$\dot{s} = -\frac{\partial H(P_s(t), P_{req}(t), n(t), s(t))}{\partial E(t)} = 0 \rightarrow s = \text{konstant}. \quad (13)$$

Folglich kann die optimale Leistung  $P_{s,opt}(t)$  durch eine Minimierung der in diesem Fall konkav modellierten Hamiltonfunktion (8) gefunden werden.  $P_{s,opt}(t)$  ergibt sich als eine Funktion in Abhängigkeit der Leistung  $P_{req}(t)$ , der Drehzahl  $n(t)$  und des konstanten Co-States als:

$$\frac{\partial H(P_s(t), P_{req}(t), n(t), s)}{\partial P_s(t)} = 0 \rightarrow P_{s,opt}(t) = \frac{-\gamma_1(P_{req}(t), n(t)) - s}{2\gamma_2(P_{req}(t), n(t))}. \quad (14)$$

Um nun mithilfe von (14) die optimale Leistung  $P_{s,opt}(t)$  bestimmen zu können, muss ein optimaler Co-State  $s_{opt}$  gefunden werden, welcher die Einhaltung der Bedingungen (9)-(12) garantiert. Zu diesem Zweck können nun die aus der Prädiktion des zukünftigen Fahrzeugverhaltens erhaltenen, vorausliegenden Leistungen und Drehzahlen des Fahrzeugs in Kombination mit der Systemdynamik (9) und den energetischen Randbedingungen (10) und (11) verwendet werden. Mithilfe einer diskreten Betrachtung des gesamten Reisehorizonts kann mithilfe von (9)-(11) die Systemdynamik über den gesamten Reisehorizont hinweg zu

$$\Delta E = E_{Ende} - E_{Start} = -\sum_{k=0}^N P_s[k]\Delta T \quad (15)$$

zusammengefasst werden. Betrachtet man nun nur die hybridisch zu befahrenden Zeitpunkte  $\Theta$  in (15) und ersetzt  $\Delta E$  durch die für die in den hybridisch zu befahrenden Zeitpunkten zur Verfügung stehende Energie  $\Delta E_{Hyb}$ , so kann durch einsetzen von (14) in (15) und lösen nach  $s$  der optimale Co-State als

$$s_{opt} = \frac{\Delta E_{Hyb} - \sum_{j \in \theta} \gamma_1[j] / 2 \gamma_2[j] \Delta T}{\sum_{j \in \theta} 1 / 2 \gamma_2[j] \Delta T} \quad (16)$$

bestimmt werden. Bestimmt man nun auf Basis der präsentierten zweistufigen Betriebsstrategie die elektrische Fahrentscheidung und den Lastpunkt des betrachteten PHEV mithilfe einer idealen Prädiktion des Fahrzeugverhaltens, so ergeben sich für einen realen Fahrzyklus die in Abbildung 5 gezeigte resultierende State-of-Charge-Trajektorie der Fahrzeughbatterie und die resultierende elektrische Fahrentscheidung.

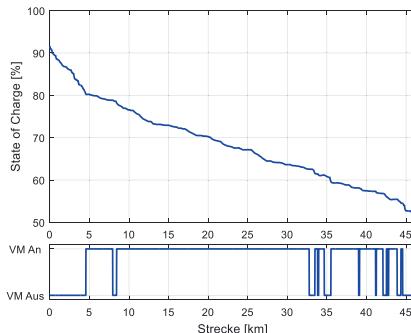


Abbildung 5: Ergebnis einer globalen Betriebsstrategie mit regelbasierter elektrischer Fahrentscheidung.

#### 4. Globale Betriebsstrategie mit einer optimierungsbasierten elektrischen Fahrentscheidung

Alternativ zu der in Kapitel 3 vorgestellten Betriebsstrategie kann mit der in [5] präsentierten Methode eine durchgehend auf PMP basierende Betriebsstrategie für PHEV angewandt werden. Zu diesem Zweck wird die in Kapitel 3 definierte Hamiltonfunktion (8) durch die Boolesche Entscheidungsvariable  $u_E(t)$  erweitert. Dadurch ergibt sich die Hamiltonfunktion zu

$$H(P_s(t), P_{req}(t), u_E(t), n(t), s) = P_f(P_s(t), P_{req}(t), u_E(t), n(t)) + sP_s(t) = \\ u_E(t) (\gamma_0(P_{req}(t), n(t)) + \gamma_1(P_{req}(t), n(t)) P_s(t) + \gamma_2(P_{req}(t), n(t)) P_s(t)^2) + sP_s(t). \quad (17)$$

Durch die Verwendung der Booleschen Entscheidungsvariable  $u_E(t)$  erhält man somit die Hamiltonfunktion für den Fall einer geschlossenen Kupplung und eines laufenden Verbrennungsmotors ( $u_E(t) = 1$ ) als

$$H_{an}(P_s(t), P_{req}(t), u_E(t), n(t), s) = \\ \gamma_0(P_{req}(t), n(t)) + \gamma_1(P_{req}(t), n(t)) P_s(t) + \gamma_2(P_{req}(t), n(t)) P_s(t)^2 + sP_s(t) \quad (18)$$

und die Hamiltonfunktion für den Fall einer geöffneten Kupplung und eines abgeschalteten Verbrennungsmotors ( $u_E(t) = 0$ ) als

$$H_{aus}(P_{s,aus}(t), P_{req}(t), u_E(t), n(t), s) = s P_{s,aus}(t). \quad (19)$$

Die Leistung  $P_{s,aus}(t)$  beschreibt hierbei die notwendige elektrische Leistung welche für einen rein elektrischen Vortrieb des Fahrzeugs eingesetzt werden muss. Basierend auf der Optimalsteuerungstheorie kann somit in jedem Zeitschritt eine optimierungsbasierte elektrische Fahrentscheidung durch einen Vergleich der in (18) und (19) beschriebenen Hamiltonfunktionen nach der folgenden Vorschrift erfolgen, falls der konstante Co-State  $s$  bekannt ist:

$$u_E(t) = \begin{cases} 0 \text{ (→ elektrisches Fahren)} & \text{falls } H_{an}(t) \geq H_{aus}(t) \\ 1 \text{ (→ hybrides Fahren)} & \text{falls } H_{an}(t) < H_{aus}(t) \end{cases} \quad (20)$$

Somit muss wiederum der für die aktuelle Reise gültige, optimale Co-State und die dazu korrespondierenden optimalen Leistungen vorab bestimmt werden. Zu diesem Zweck wird die folgende, in [5] präsentierte, iterative Berechnungsvorschrift verwendet: Zuerst wird der optimale Co-State und die zugehörige optimale Lastpunktverteilung in jedem Zeitschritt der vorliegenden Reise für den Fall eines laufenden Motors und geschlossener Kupplung ( $u_E(t) = 1$ ) wie in Kapitel 3 gezeigt durch (14)-(16) bestimmt. Anschließend erfolgt in einem nachgelagerten Schritt auf Basis der aus Schritt eins bekannten optimalen Größen die in (20) definierte elektrische Fahrentscheidung. Dadurch erfolgt eine Gruppierung in elektrisch und hybride zu befahrende Zeitpunkte. Anschließend wird in einem dritten Schritt der optimale Co-State für die auf Basis von (20) verbleibenden, hybriden zu befahrenden Zeitpunkte erneut berechnet. Anschließend kann auf Basis des neu berechneten Co-States die elektrische Fahrentscheidung erneut in jedem Zeitschritt bestimmt werden. Dieser Ablauf wird anschließend solange wiederholt bis der Algorithmus konvergiert und eine optimale Lösung gefunden wurde (vgl. [5]). Bestimmt man nun auf Basis der präsentierten optimierungsbasierten Betriebsstrategie die elektrische Fahrentscheidung und den Lastpunkt

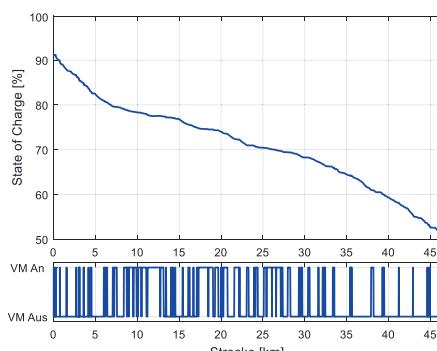


Abbildung 6: Ergebnis einer globalen Betriebsstrategie mit optimierter elektrischer Fahrentscheidung.

des betrachteten PHEV mithilfe einer idealen Prädiktion des Fahrzeugverhaltens, so ergibt sich die für einen realen Fahrzyklus in Abbildung 6 gezeigte resultierende State-of-Charge-Trajektorie der Fahrzeugbatterie und die resultierende elektrische Fahrentscheidung. Betrachtet man die resultierenden Motor-Starts in Abbildung 6, so lässt sich ein sehr hochfrequentes Start-Verhalten feststellen. Da dieses Verhalten zu einem erhöhten Verbrauch durch die auftretenden Motor-Start-Kosten führen kann und ein sehr unangenehmes, für den Kunden nicht nachvollziehbares, Verhalten des Fahrzeugantriebes erzeugt, wird im Folgenden eine Erweiterung des in [5] präsentierten Ansatzes vorgestellt, mit dessen Hilfe die Motor-Starts deutlich reduziert werden können.

## 5. Einführung eines Strafterms zur Reduktion hochfrequenter Motor-Starts

Um das hochfrequente Motorstart Verhalten der in Kapitel 6 präsentierten Strategie reduzieren zu können, kann wie in [7], [8] und [9] gezeigt, ein Strafterm für einen Motorstart in die Kostenfunktion wie folgt integriert werden:

$$\begin{aligned} J(P_s(t), P_{req}(t), x_E(t), u_E(t), n(t)) = \\ P_f(P_s(t), P_{req}(t), u_E(t), n(t)) + \mu_{Start} F(x_E(t), u_E(t)). \end{aligned} \quad (21)$$

Unter der weiteren Annahme eines konstanten Co-States ergibt sich die Hamiltonfunktion zu

$$\begin{aligned} H(P_s(t), P_{req}(t), x_E(t), u_E(t), n(t), s) = \\ P_f(P_s(t), P_{req}(t), u_E(t), n(t)) + \mu_{Start} F(x_E(t), u_E(t)) + s P_s(t). \end{aligned} \quad (22)$$

Hierbei stellt  $\mu_{Start}$  den Strafterm für einen Motorstart dar. Darüber hinaus repräsentiert  $F(x_E(t), u_E(t))$  eine von der Booleschen Entscheidungsvariable  $u_E(t)$  und dem Motorstatus  $x_E \in \{0,1\}$  abhängige Funktion.  $x_E$  ergibt sich dabei aus dem Eingang  $u_E$ . Somit signalisiert  $F(x_E(t), u_E(t))$  einen Motorstart wie folgt:

$$F(x_E(t), u_E(t)) = \begin{cases} 1 & \text{falls } x_E(t) = 0 \wedge u_E(t) = 1 \\ 0 & \text{sonst} \end{cases}. \quad (23)$$

Die in (22) definierte Hamiltonfunktion kann wiederum in dem in Kapitel 6 vorgestellten Verfahren verwendet werden um die Betriebsstrategie des PHEV zu bestimmen. Um einen bestmöglichen Wert für  $\mu_{Start}$  zu identifizieren, wurden der Verbrauch und die Anzahl der Motorstarts für ein vordefiniertes Raster von  $\mu_{Start} \geq 0$  simuliert und die Ergebnisse in Abbildung 7 visualisiert. Hierfür wurde ausgehend von  $\mu_{Start} = 0$  der Wert des Strafterms sukzessive erhöht. Wie zu erwarten sinkt der Verbrauch für einen steigenden Wert von  $\mu_{Start}$  bis zu einem Minimum und steigt anschließend wieder an. Betrachtet man nun die resultierenden Verläufe in Abbildung 7, so bieten sich zwei Strafterme für eine Applikation an:  $\mu_{Start,1}$ , welcher eine höhere Anzahl an Motorstarts erlaubt aber in einem minimalen Verbrauch

resultiert, oder  $\mu_{Start,2}$ , welcher einen Trade-Off zwischen Verbrauchsoptimalität und einer möglichst geringen Anzahl an Motorstarts bereitstellt. Da in der Praxis der Fahrkomfort des

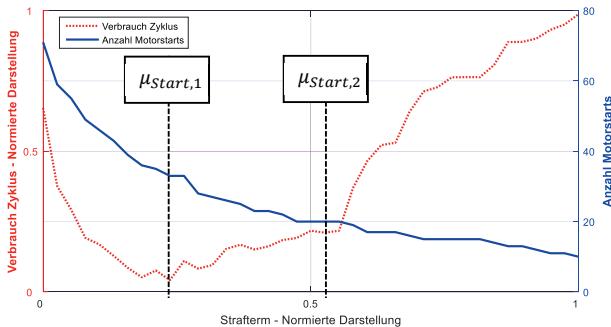


Abbildung 7: Auswirkung des verwendeten Strafterms auf Verbrauch und Anzahl der Motorstarts

Fahrzeugs möglichst angenehm ausgelegt werden soll, stellt hierbei  $\mu_{Start,2}$  die aus Praxis Sicht gegebenenfalls bessere Wahl dar, da durch geringe Verbrauchseinbußen die Anzahl der Motorstarts um weitere 13 Starts gesenkt werden kann (Vergleiche Tabelle 1).

## 6. Ergebnisse und Ausblick

Nachdem in den vorausgegangenen Kapiteln verschiedene Methoden für die Einstellung der elektrischen Fahrentscheidung vorgestellt wurden, werden in diesem Kapitel die resultierenden Ergebnisse aufgezeigt und diskutiert. Zu diesem Zweck sind die resultierenden Kraftstoffverbräuche und die zugehörige Anzahl an Motorstarts in Tabelle 1 zusammengefasst.

Tabelle 1: Resultierende Kraftstoffverbräuche und Anzahl der Motorstarts

	Elektrische Fahrentscheidung					
	Regelbasiert	Optimierungsbasiert ohne Strafterm	Optimierungsbasiert mit appliziertem Strafterm		$\mu_{Start,1}$	$\mu_{Start,2}$
			$\mu_{Start,1}$	$\mu_{Start,2}$		
Kraftstoffverbrauch	111.37%	100%	98.23%	98.72%		
Anzahl Motorstarts	11	71	33	20		

Betrachtet man die Kraftstoffverbräuche in Tabelle 1, so lässt sich erkennen, dass die Verwendung einer regelbasierten elektrischen Fahrentscheidung in einem deutlich erhöhten Kraftstoffverbrauch resultiert. Die Verwendung einer optimierungsbasierten elektrischen Fahrentscheidung resultiert hingegen in einem deutlich niedrigeren Kraftstoffverbrauch, welcher durch die Einführung eines applizierten Strafterms noch weiter abgesenkt werden kann. Betrachtet man hingegen die auftretende Anzahl an Motorstarts, so wird ersichtlich, dass bei der Verwendung einer regelbasierten elektrischen Fahrentscheidung eine viel geringere Anzahl an Motorstarts benötigt wird, als bei der Verwendung einer optimierungsbasierten elektrischen Fahrentscheidung. Die bei der Verwendung einer optimierungsbasierten

elektrischen Fahrentscheidung auftretende hohe Frequenz an Motorstarts lässt sich zwar durch die Integration eines applizierten Strafterms noch deutlich reduzieren, bleibt jedoch weiterhin deutlich über der Anzahl der Motorstarts einer regelbasierten elektrischen Fahrentscheidung. Zusammenfassend lässt sich feststellen, dass durch die Verwendung einer regelbasierten elektrischen Fahrentscheidung das für den Fahrer angenehmste Motor-Start-Stopp-Verhalten erreicht werden kann, dies jedoch mit einer Erhöhung des Kraftstoffverbrauchs einher geht. Im Gegensatz dazu kann der niedrigste Kraftstoffverbrauch durch eine optimierungsbasierte elektrische Fahrentscheidung erreicht werden, wobei ein zusätzlicher Strafterm eingeführt werden muss, um die Anzahl der benötigten Motorstarts abzusenken. Abschließend lässt sich somit die Verwendung der in [5] präsentierten, echtzeitfähigen und konsistent auf PMP basierenden Betriebsstrategie in Kombination mit einem applizierten Strafterm empfehlen, da sich dadurch der bestmögliche Kraftstoffverbrauch in Kombination mit einem für den Fahrer akzeptablen Motor-Start-Stopp-Verhalten erzielen lässt.

#### **Literaturverzeichnis:**

- [1] Ambühl, D., Sundström, O. and Guzzella, L. (2010). Explicit optimal control policy and its practical application for hybrid electric powertrains. *Control Engineering Practice*, 18, 1429-1439.
- [2] Kim, N., Cha, S., and Peng, H. (2011). Optimal control of hybrid electric vehicles based on Pontryagin's minimum principle. *IEEE Transactions on Control Systems Technology*, 19, 1279-1287.
- [3] Kim, N.W., Lee, D.H., Zheng, C., Shin, C., Seo, H., and Cha, S.W. (2014). Realization of PMP-based Control for hybrid electric vehicles in a backward-looking simulation. *International Journal of Automotive Technology* 15, 635-635.
- [4] Serrao, L., Onori, S., Rizzoni, G. (2009). ECMS as a realization of Pontryagin's minimum principle for HEV control. *American Control Conference*, 3964-3969.
- [5] Schmid, R., Bürger, J., and Bajcinca, N. (2019). A comparison of PMP-based Energy Management Strategies for Plug-in-Hybrid Electric Vehicles. *IFAC International Symposium on Advances in Automotive Control* (Accepted).
- [6] Geering, H. P. (2007) *Optimal Control with Engineering Applications*. Springer.
- [7] Sciarretta, A., Back, M., and Guzzella, L. (2004) Optimal Control of Parallel Hybrid Electric Vehicles. *IEEE Transactions on Control Systems Technology*, 12, 352-363.
- [8] Kutter, S. (2013) Eine prädiktive und optimierungsbasierte Betriebsstrategie für autarke und extern nachladbare Hybridfahrzeuge, Dissertation, TU Dresden
- [9] Nüesch, T. (2014) Energy Management of Hybrid Electric Vehicles. Dissertation, ETH Zürich.

# Simulation von Hybrid-Nutzfahrzeugen mittels akausaler Optimierung der Betriebsstrategie

Dr.-Ing. **Mario Greule**, Dipl.-Ing. **York Stoermer**,  
Daimler Buses, EvoBus GmbH, Mannheim

## Zusammenfassung

Zur Bewertung von Hybrid-Nutzfahrzeugen im Konzeptstadium sind Kenntnisse über die Betriebsstrategie erforderlich. Diese stehen jedoch nicht zu Beginn des Entwicklungszyklus zur Verfügung. Daher ist zur Bewertung der Konzepte eine Simulationsumgebung mit einer prototypischen Betriebsstrategie erforderlich. Um nicht für jedes Konzept eine neue Strategie entwickeln zu müssen, wurde hierfür eine allgemeine Lösung unter Anwendung des Optimierungsverfahrens Dynamische Programmierung umgesetzt. Mit dieser Simulationsumgebung werden die Potentiale eines Hybridantriebstrangs auf der jeweils betrachteten Strecke ausgewiesen. Neben diesem Vorteil lassen sich durch die Optimierung auch wertvolle Erkenntnisse für die anschließende Serienentwicklung der Betriebsstrategie ableiten. In dieser Arbeit werden die Simulationsumgebung sowie exemplarische Erkenntnisgewinne für die Entwicklung der Betriebsstrategie vorgestellt.

## Abstract

The evaluation of hybrid commercial vehicles at the concept stage requires knowledge of the operational strategy. However, these are not available at the beginning of the development cycle. Therefore, a simulation environment with a prototypical operating strategy is necessary to evaluate the concepts. In order to prevent the development of a new strategy for each concept, a general solution has been implemented for this purpose using the dynamic programming optimization method. With this simulation environment, the potentials of a hybrid powertrain are shown on the considered driving cycle. In addition to this advantage, the optimization can also be used to derive valuable insights for the subsequent series development of the operating strategy. In this paper the simulation environment as well as exemplary insights for the development of the operating strategy are presented.

## Einleitung

Das Akronym CASE bilden einen integralen Bestandteil der Daimler Unternehmensstrategie und das über alle Business Units hinweg, von den Personenkraftwagen bis zu den Nutzfahrzeugen. Die Buchstaben in CASE stehen dabei für:

C – Connected / Vernetzung

A – Autonomous / Autonomes Fahren

S – Shared and Services / Mobilitätsdienstleistungen

E – Electric / Elektrische Antriebe

Drei der vier Kernpunkte der Strategie haben damit einen direkten Einfluss auf die Betriebsstrategie der zukünftigen Nutzfahrzeuge – nämlich Vernetzung, Autonomes Fahren und Elektrische Antriebe.

Durch die Vernetzung der Fahrzeuge untereinander und durch den Zugriff auf Daten außerhalb des Fahrzeugs können Informationen über den zukünftigen Streckenverlauf, Ereignisse sowie Umgebungsbedingungen verarbeitet und für die Betriebsstrategie herangezogen werden. So ist es beispielsweise durch umfassendes Kartenmaterial in einer Cloud möglich bevorstehende Steigungsfahten zu berücksichtigen oder durch die Information über einen Wetterumschwung das Klima im Fahrgastinnenraum eines Busses energieoptimal und komfortabel einzustellen.

Autonom fahrende Fahrzeuge besitzen darüber hinaus eine Vielzahl an integrierter Sensorik, die ebenfalls eine vorausschauende Betriebsstrategie ermöglicht. Darüber hinaus muss die gesamte vorgelagerte Intelligenz, wie das Beschleunigen, Abbremsen und Lenken, durch das Fahrzeug selbst übernommen werden. Letzteres kann im weiteren Sinne auch zur Betriebsstrategie hinzugezählt werden, ist jedoch nicht im Fokus dieser Arbeit.

Vielmehr zielt der Fokus dieser Arbeit auf den Einfluss von elektrischen bzw. hybridischen Antrieben ab. Im Gegensatz zu konventionellen Fahrzeugen, bei denen die Betriebsstrategie im Wesentlichen von der Schaltstrategie und der Parametrierung des Verbrennungsmotors abhängt, sind bei elektrischen Fahrzeugen der Ladezustand (SOC, engl. state of charge) und die Leistungsgrenzen der Batterie von hoher Bedeutung für die Betriebsstrategie. Bei hybriden Fahrzeugen haben sowohl die Einflussfaktoren der konventionellen als auch der elektrischen Antriebe eine Bedeutung für die Betriebsstrategie. Darüber hinaus hat die Leistungsaufteilung zwischen elektrischem Antrieb und Verbrennungsmotor einen großen Einfluss auf den Energieverbrauch und die Anforderung an die einzelnen Komponenten.

Aufgrund dieses hohen Einflusses der Leistungsaufteilung ist dieser Teil der Betriebsstrategie bereits zu Beginn der Entwicklung von großer Bedeutung. Jedoch ist zu einem frühen Entwicklungsstadium weder eine Betriebsstrategie noch die Konfiguration der Komponenten definiert, weshalb hier eine allgemeine Lösung herangezogen werden muss. Solch eine allgemeine Lösung wurde bei Daimler Buses in eine Simulationsumgebung zur Bewertung von Fahrzeugkonzepten integriert. Somit ist es möglich bei der Definition der Fahrzeuganforderungen zu

unterstützen und bereits zu Beginn des Entwicklungszyklus Erkenntnisse für die spätere Umsetzung der Betriebsstrategie zu gewinnen.

### Modellbasierte Konzeptauslegung

Die Fahrzeugentwicklung bei Daimler Buses erfolgt nach dem klassischen V-Modell und einer darauf basierenden modellbasierten Erweiterung [1], siehe Abbildung 1.

Durch den Einsatz unterschiedlicher Simulationswerkzeuge kann die Fahrzeugentwicklung unterstützt und zu einem frühen Stadium im Entwicklungsprozess getestet werden. Dadurch werden unausgereifte Konzepte und Fehler frühzeitig erkannt und somit Zeit und Kosten gegenüber einem nicht-modell-basierten Ansatz gespart, da sich Fehler umso stärker auswirken je später Sie identifiziert werden [2]. Wie in Abbildung 1 zu sehen, kommen dabei unterschiedliche Simulationsumgebungen zum Einsatz. Zu einem frühen Entwicklungsstadium sind Komponenten und die Fahrzeugfunktionen noch nicht definiert und daher kommt eine spezielle Simulationsumgebung zur Bewertung von Fahrzeugkonzepten zur Anwendung. Nicht definiert ist demnach auch die Betriebsstrategie zur Aufteilung der Antriebsleistung von Hybridfahrzeugen. Sobald die Komponentendaten definiert und die Fahrzeugfunktionen zur Verfügung stehen, können diese in einer Detailsimulationsumgebung getestet und weiter optimiert werden. Dies steht jedoch nicht im Fokus dieser Arbeit, weshalb im Folgenden näher auf die Simulationsumgebung zur Bewertung von Fahrzeugkonzepten und deren Implementierung der Betriebsstrategie des Antriebsstrangs eingegangen wird.

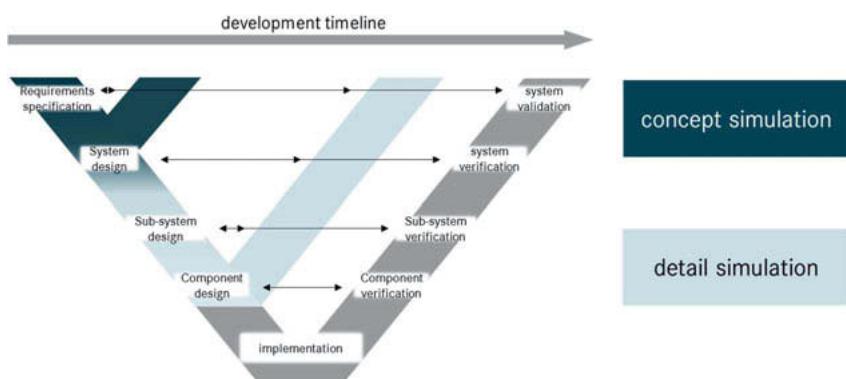


Abbildung 1: Modellbasiertes Entwicklungsprozess [1]

## Simulationsumgebung zur Bewertung von Fahrzeugkonzepten

Die Simulationsumgebung zur Bewertung von Fahrzeugkonzepten, kurz Konzeptbewertungstool, wurde Daimler-Buses-intern entwickelt und besteht im Wesentlichen aus einem Fahrzeugkonfigurations-, einem Berechnungs- und einem Analyseteil.

Im Fahrzeugkonfigurationsteil können folgende Fahrzeug-Topologien mit unterschiedlichen Komponenten und Fahrzeugeigenschaften angelegt werden:

- Konventionelle Fahrzeuge mit Verbrennungsmotor
- Parallelhybride mit elektrischem Antrieb und Verbrennungsmotor
- Serielle Hybride mit elektrischem Antrieb und einem Dieselgenerator
- Brennstoffzellenfahrzeuge
- und vollelektrische Fahrzeuge

Die Komponenten und Fahrzeugeigenschaften jeder dieser Fahrzeugtopologien sind über einen individuellen Datensatz definiert. Dieser Datensatz umfasst entsprechend Abbildung 2 die Schnittstellen, die Eigenschaftsparameter und die Verhaltensfunktion der jeweiligen Komponente bzw. Fahrzeugeigenschaft. Dadurch lässt sich das Fahrzeugmodell sehr flexibel aufbauen.

Zur anschließenden Berechnung der verketteten Verhaltensfunktionen in einem Gesamtfahrzeugmodell ist zudem die Definition von Randbedingungen erforderlich. In der Praxis sind die Randbedingungen üblicherweise durch eine Streckenvorgabe definiert, d.h. ein gewisses Ge-

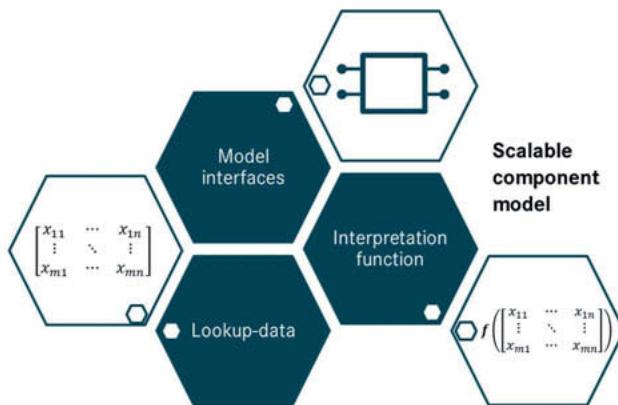


Abbildung 2: Modulare Struktur eines Komponentenmodells

schwindigkeits- und Steigungsprofil über der Zeit. Darüber hinaus ist es in dem Konzeptbewertungstool auch möglich die Drehzahl und/oder das Drehmoment einzelner Antriebstrangkomponenten vorzugeben.

Die Berechnung des vorgegebenen Fahrzenarios erfolgt durch eine zeitschrittisierte dynamische Lösung des Fahrzeugmodells unter Berücksichtigung der Betriebsstrategien. Diese Betriebsstrategien werden im Folgenden für Nutzfahrzeuge mit konventionellem, voll-elektrischem und hybrider Antriebssystem näher erläutert.

Für konventionelle Nutzfahrzeuge hat die Schaltstrategie einen großen Einfluss auf den Kraftstoffverbrauch. Diese ist im Konzeptbewertungstool nach einem regelbasierten Ansatz anhand von Schaltpolygonen implementiert. Dieser Ansatz erfolgt analog der Umsetzung im VECTO Tool, welches von der TU Graz für die CO<sub>2</sub>-Gesetzgebung der europäischen Union entwickelt wurde [2]. In Abbildung 3 ist dargestellt wie das Prinzip funktioniert. Darin sind drei Polygone über dem Drehzahl-Drehmoment-Bereich des Verbrennungsmotors eingezeichnet. Im aktuellen Gang befindet sich der Motorbetriebspunkt innerhalb des weißen Polygons. Sobald sich jedoch Drehzahl und Drehmoment derart verändern, dass eine Transition in den blauen oder roten Bereich erfolgt, wird ein Herunterschalten (Downshift) bzw. Hochschaltvorgang (Upshift) ausgelöst. Streng genommen wird vor der Schalthandlung noch geprüft, ob das anschließende Drehmoment einen ausreichenden Abstand zu dem angeforderten Drehmoment aufweist. Ist dies nicht der Fall, wird die Schaltung unterdrückt bzw. der entsprechende Gang übersprungen.

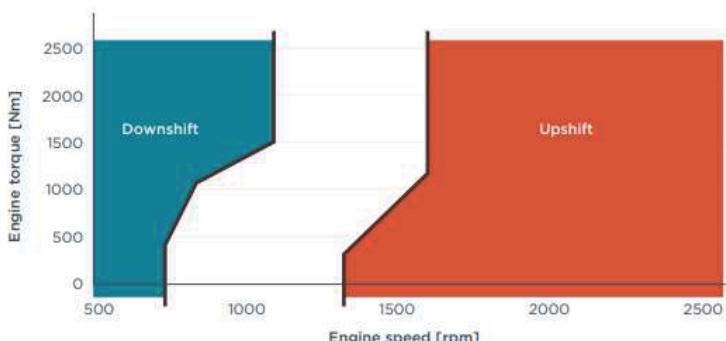


Abbildung 3: Exemplarische Schaltpolygone

Quelle: VECTO user manual [3]

Bei voll-elektrischen Fahrzeugen bestehen wenige Freiheitsgrade bei der Betriebsstrategie des Antriebstrangs. Es ist lediglich zu beachten, dass die Leistungsbegrenzung bei hohem und niedrigem SOC korrekt abgebildet wird. Dies erfolgt anhand von fest parametrierten Schwellenwerten und anhand des Leistungsquantums zur Erreichung des maximalen oder minimalen SOC-Levels.

Weitaus Komplexer ist die Implementierung einer universellen Betriebsstrategie von Hybridfahrzeugen. Aufgrund der unterschiedlichen Energiespeicher Batterie und Diesel- bzw. H<sub>2</sub>-Tank muss zu jedem Betriebspunkt entschieden werden welcher Speicher in welchem Umfang zur Umsetzung der Fahrernergie genutzt wird. Ziel ist es dabei einen möglichst geringen Kraftstoffverbrauch zu erzielen, unter Einhaltung gewisser Vorgaben für die Energiebilanz der Batterie. Diese Vorgabe variiert je nach Hybridisierungsgrad. Ein sogenannter Mild- oder Full-Hybrid ermöglicht kein Nachladen der Batterie und muss daher mit einer ausgeglichenen Energiebilanz betrieben werden. Ein sogenannter Plug-In-Hybrid besitzt eine Nachlademöglichkeit und kann daher auch mit einer negativen Energiebilanz über das Fahrzeug betrieben werden. Die Implementierung einer solchen Betriebsstrategie im Fahrzeug ist stark abhängig von der Leistungsfähigkeit der Komponenten. Diese sollen im Konzeptstadium jedoch variiert werden können, weshalb in dem Konzeptbewertungstool eine universelle Optimierungsmethode, die Dynamische Programmierung (DP) [3], Anwendung findet.

Die DP ist eine akausale Methode, die komplexe Optimierungsprobleme in einfachere überlappende und wiederkehrende Teilprobleme zerlegt. So wird beispielsweise der betrachtete Zeithorizont einer dynamischen Simulation in kleine Zeitschritte zerlegt. Jedes dieser Teilprobleme wird für sich gelöst und das optimale Ergebnis gespeichert. Unter der Voraussetzung, dass die Teilprobleme überlappend und wiederkehrend sind, lassen sich die Teillösungen anschließend wieder zu einem komplexen Optimum zusammenfügen. Überlappend heißt in dem oben genannten Beispiel, dass jeder Zeitschritt berücksichtigt wird und Wiederkehrend, dass das Optimierungsproblem für jeden Zeitschritt gleich ist. Somit lassen sich Probleme von beliebiger Komplexität lösen, sofern die Rechen- und Speicherkapazität dafür ausreichend bemessen sind. Weiterhin ist zu beachten, dass das Optimierungsproblem bereits vorab über den gesamten Optimierungshorizont bekannt sein muss. Damit ist die DP aksual und nicht ohne weiteres für Optimierungsprobleme im laufenden Betrieb anwendbar.

Die Umsetzung im Konzeptbewertungstool erfolgt anhand des Ansatzes von Sundström und Guzzella [4]. Dazu muss zunächst einmal gewährleistet werden, dass das Fahrzeug einem

gewünschten Fahrzyklus, respektive dem geforderte Geschwindigkeitsprofil und der Topographie, folgen kann. Ist dies gewährleistet, bestehen je zwei Stellgrößen pro Zeitschritt um die Leistungsverteilung zu beeinflussen – die Leistung des Batteriespeichers und die Leistung der Brennstoffzelle bzw. des Verbrennungsmotors. Dadurch, dass die Summenleistung  $P_{\text{dem}}$  pro Zeitschritt  $t$  bekannt ist, kann der Freiheitsgrad auf eine Variable  $k$  reduziert werden:

$$\begin{aligned} P_{\text{dem}}(t) &= P_{\text{bat}}(t) + P_{\text{eng}}(t) \\ k &= \frac{P_{\text{bat}}}{P_{\text{dem}}} = 1 - \frac{P_{\text{eng}}}{P_{\text{dem}}} \end{aligned} \quad (1)$$

mit der Leistungsanforderung der Batterie  $P_{\text{bat}}$  sowie der Brennstoffzelle bzw. des Motors  $P_{\text{eng}}$ . Für dieses Beispiel ergibt sich damit eine Zustandsgröße, die dem SOC der Batterie entspricht. Um die DP durchführen zu können werden sowohl die Zeitschritte  $t \in [t_1, t_N]$ , als auch die Leistungsaufteilung  $k \in [k_1, k_M]$  und die SOC-Zustände  $x \in [x_1, x_L]$  diskretisiert. Eine Visualisierung des Algorithmus erfolgt in Abbildung 4. Das Optimierungsproblem wird zunächst von hinten nach vorne (blau) und anschließend von vorne nach hinten durchlaufen (rot).

Das Teilproblem der DP besteht darin für einen Zeitschritt  $t_n$  sämtliche Leistungsaufteilungen  $k$  für jeden Zustand  $x$  mit Hilfe des Fahrzeugmodells zu berechnen, um mit dem geringsten Kraftstoffverbrauch in die Zustände zum Zeitpunkt  $t_{n+1}$  zu gelangen. Dabei ist zu beachten, dass den Zuständen  $x$  zum Zeitpunkt  $t_{n+1}$  ebenfalls ein Kraftstoffverbrauchswert zugeordnet ist, der sich aus den aggregierten Kraftstoffverbrauchswerten der Transitionen vom Zeitpunkt  $t_{n+1}$  bis zum letzten Zeitpunkt  $t_N$  ergeben. Daran wird deutlich, dass die DP das Optimierungsproblem zunächst von hinten nach vorne durchläuft. Da die diskreten Leistungsaufteilungen  $k$  die Zielzustände  $x$  zum Zeitpunkt  $t_{n+1}$  nicht exakt erreichen, werden die aggregierten Kraftstoffwerte zum Zielzeitpunkt linear interpoliert. Neben dem minimalen aggregierten Kraftstoffverbrauch wird in den Zuständen zum Zeitpunkt  $t_n$  auch die Leistungsaufteilung  $k$  gespeichert, die zum geringsten aggregierten Kraftstoffverbrauch im jeweiligen Zustand führt. Somit wird von hinten nach vorne für jeden Zeitschritt und für jeden Zustand berechnet welcher aggregierte Kraftstoff bis zum Ziel erforderlich ist und welche Leistungsaufteilung dafür ideal ist. Sollen im letzten Zeitschritt bestimmte Zustände vom Lösungsraum ausgeschlossen werden, so können diese mit einem unendlichen Kraftstoffverbrauchswert belegt werden.

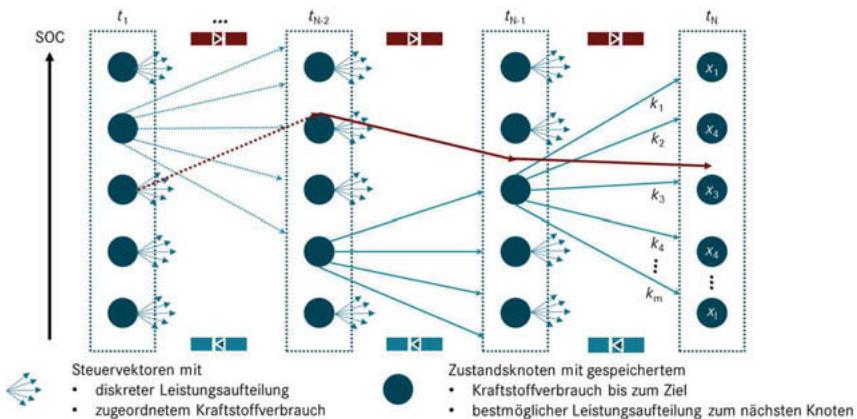


Abbildung 4: Funktionsprinzip der implementierten Dynamischen Programmierung (DP)

Im Anschluss an den Rückwärtsdurchlauf werden die gelösten Teilprobleme wieder zu einem komplexen Problem zusammengefügt. Dazu wird von einem beliebigen Anfangszustand zum Zeitpunkt  $t_1$  für jeden Knoten das Fahrzeugmodell mit der gespeicherten Leistungsaufteilung durchlaufen und der zugehörige Kraftstoffverbrauch gespeichert. Da das Problem im Rückwärtsdurchlauf für jeden Zeitzustand diskret gelöst wurde, erfolgt nun eine Interpolation der einzelnen Zeitschrittlösungen um ein zusammenhängendes Ergebnis zu erhalten.

Diese Methode ermöglicht es eine universelle, nämlich von der Fahrzeugkonfiguration und vom Szenario unabhängige, Betriebsstrategie anzuwenden. Es ist allerdings zu beachten, dass diese Betriebsstrategie implizit eine Vorausschau über die gesamte Strecke voraussetzt. Durch diese vorausschauende Optimierung lassen sich aus den Ergebnissen wiederum interessante Erkenntnisse für die anschließende Serienentwicklung ableiten.

### Anwendungsbeispiel

Um das Resultat einer optimierten Betriebsstrategie und mögliche Erkenntnisgewinne darzustellen, wird im Folgenden das Ergebnis eines exemplarischen Diesel-Hybrid Stadtbusses vor gestellt. Dieser Bus wird auf der Strecke CO2-Urban betrieben, deren Geschwindigkeits- und Steigungsverlauf in Abbildung 5 zu sehen sind. Direkt darunter in Abbildung 6 ist der resultierende Ladezustandsverlauf (SOC) der Batterie dargestellt. Es ist ersichtlich, dass die Batterie

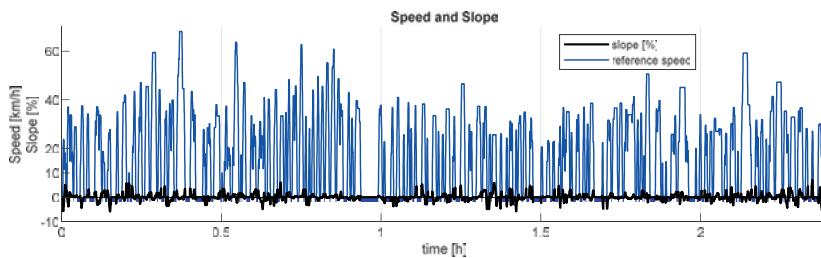


Abbildung 5: Geschwindigkeits- und Topographieverlauf der CO2-Urban Strecke

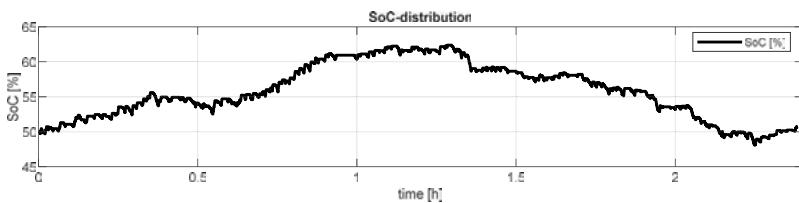


Abbildung 6: SOC-Verlauf der exemplarischen Fahrzeugkonfiguration

mit einem Start-SOC von 50 % und auch einem Ziel-SOC von ca. 50 % endet – damit wird das Fahrzeug mit einer ausgeglichenen Energiebilanz betrieben. Des Weiteren ist zu sehen, dass der SOC zunächst auf ca. 62 % ansteigt und danach wieder abnimmt. Daraus lassen sich direkt zwei Rückschlüsse ziehen. Der erste bezieht sich auf die Fahrzeugkonfiguration und besagt, dass die Beispielkonfiguration für dieses Betriebsszenario nicht optimal ausgelegt ist. Die mitgeführte Kapazität wird nicht voll ausgeschöpft und damit könnte die Batterie kleiner bemessen werden. Dies würde sowohl die Systemkosten, als auch das Gewicht und somit den Energieverbrauch reduzieren. Der zweite Rückschluss, der aus dem Ergebnis gewonnen werden kann, bezieht sich auf die Betriebsstrategie. Es scheint sich positiv auf den Kraftstoffverbrauch auszuwirken, wenn die Batterie mit einem hohen SOC betrieben wird. Ansonsten würde der SOC nicht zunächst ansteigen und danach wieder fallen – ein um den Mittelwert von 50 % schwankender SOC wäre nämlich ebenfalls denkbar. Die anschließende Analyse dieser Auffälligkeit offenbart, dass die Batterie einen höheren Wirkungsgrad bei hohen SOC-Werten aufweist. Der Grund hierfür ist eine zunehmende elektrische Spannung mit steigenden SOC und bei gleichbleibender Leistung folgt somit ein geringerer Strom. Da die elektrischen Verluste der Batterie sich wiederum quadratisch zur Höhe des Stromeffektivwerts verhalten, steigt durch einen höheren SOC die Effizienz des Fahrzeugs. Somit lässt sich für

die spätere Funktionsentwicklung des Fahrzeugs schließen, dass bei ausreichendem Freiheitsgrad bevorzugt auf einen hohen SOC-Wert zu achten ist. Je nach Batterietechnologie und der damit einhergehenden Charakteristik der Leerlaufspannung kann das Potential dieser Empfehlung jedoch stark variieren.

Weitere Erkenntnisse lassen sich aus dem dargestellten Teilszenario in Abbildung 7 schließen. Darin wird der Bus zunächst auf ca. 40 km/h beschleunigt, dann für ca. 1 min auf dieser Geschwindigkeit gehalten und anschließend wieder bis zum Stillstand abgebremst. Darunter ist die relative Leistungsaufteilung des Antriebstrangs dargestellt. Die Farbe Blau stellt dabei die geforderte (negativer Wert) oder überschüssige Leistung (positiver Wert) des Fahrzeugs dar. Orange repräsentiert die Nebenverbraucher, Grau die mechanische Bremsleistung, Rot die Leistung des Dieselmotors und Grün die Leistung des Elektromotors. Es ist zu sehen, dass zu dem Beschleunigungsvorgang überwiegend der Verbrennungsmotor genutzt wird und nur sehr kurzzeitig der Elektromotor um zu boosten. Vielmehr wird der Elektromotor dazu genutzt, um die erforderliche Leistung für die Konstanterfahrt aufzubringen. Die dazu erforderliche Leistung wird anschließend wieder während des Abbremsvorgangs rekuperiert. Dieses Verhalten wirkt zunächst unintuitiv. Die anschließende Analyse zeigt jedoch, dass der Verbrennungsmotor, verglichen mit dem Fahrschnitt mit konstanter Geschwindigkeit, während des Beschleunigens in einem sehr guten Wirkungsgradbereich betrieben wird. Da der Elektromotor über einen weiteren Drehzahl-Drehmoment-Bereich effizient arbeiten kann, ist dieses Verhalten günstiger für einen energieoptimalen Betrieb. Das heißt, der Elektromotor sollte in der späteren Serienapplikation nicht überwiegend zum Boosten sondern vielmehr dazu verwendet werden, um ungünstige Betriebspunkte des Verbrennungsmotors zu vermeiden.

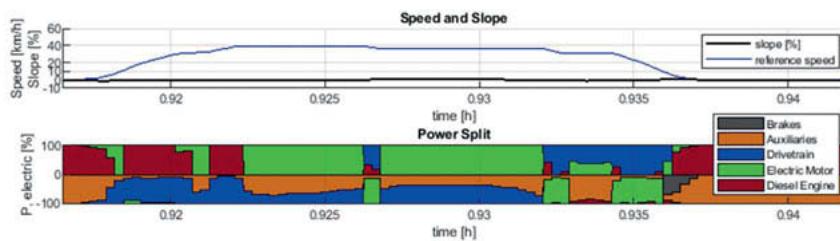


Abbildung 7: Leistungsaufteilung über einem Teilszenario bestehende aus einem Beschleunigungs-, Konstanterfahrt- und Abbremsvorgang

Dies waren nur zwei Beispiele, wie sich die Erkenntnisse aus der Betriebsstrategieoptimierung für den darauffolgenden Entwicklungsprozess nutzen lassen. Gerade das erste Beispiel zeigt jedoch wie wichtig eine prädiktive Betriebsstrategie ist und welche Potentiale sich dadurch heben lassen. Auch das berühmte Beispiel einer konstanten Bergfahrt mit anschließender Steigungsumkehr lässt sich nur optimal umsetzen (das heißt, entladen der Batterie beim Bergauffahren und wieder laden bei der anschließenden Fahrt mit negativem Gefälle), wenn sich der Streckenverlauf prädizieren lässt. Hier gibt es bereits eine Vielzahl von Ansätzen, die sich auf Kartendaten [5, 6, 7] und umfassende Sensorik [8] stützen. Durch die Vernetzung der Fahrzeuge sowie den Vorbereitungen auf das autonome Fahren, werden im Rahmen der Unternehmensstrategie CASE bereits heute die entscheidenden Voraussetzungen für eine prädiktive Betriebsstrategie vorbereitet.

## **Zusammenfassung**

Aufgrund der Tatsache, dass alternative Antriebe in Zukunft mehr und mehr an Bedeutung gewinnen werden, müssen die potentiellen Konzepte bereits heute analysiert werden. Gerade bei der Klasse der Hybridfahrzeuge muss dafür jedoch eine realistische Betriebsstrategie implementiert werden. Für diese Herausforderung wurde ein Tool vorgestellt, das eine universelle Betriebsstrategie in Form der Dynamischen Programmierung integriert hat. Dies ermöglicht zum einen die Analyse unterschiedlicher Fahrzeugkonzepte, aber zum anderen auch erste Erkenntnisse für die Implementierung der Betriebsstrategie im Fahrzeug. Perspektivisch stellt die Verbesserung von regelbasierten Betriebsstrategien jedoch nur eine Zwischenlösung dar. Durch die integrierte Daimler-Unternehmensstrategie CASE ist es auf absehbare Zeit möglich, eine optimale Betriebsstrategie auch im realen Fahrzeugbetrieb zu ermöglichen.

## **Quellen:**

- [1] M. Greule, Y. Störmer, Application of a universal simulation environment for deriving specification premises of commercial vehicles with alternative and conventional drive trains, Commercial Vehicles 2019, Baden-Baden, Germany, 2019.
- [2] European Comission, Link: [https://ec.europa.eu/clima/policies/transport/vehicles/vecto\\_en](https://ec.europa.eu/clima/policies/transport/vehicles/vecto_en), 06.04.2019
- [3] R. E. Bellman, Dynamic programming. Princeton - N.J.: Princeton, University Press, 1957.
- [4] O. Sundström, L. Guzzella, A Generic Dynamic Programming Matlab Function. 18th IEEE International Conference on Control Applications, Part of 2009 IEEE Multi-conference on Systems and Control, Saint Petersburg, Russia, July 8-10, 2009.

- [5] T. Huber, B. Kuntz, Prädiktive Betriebsstrategien im Antriebsstrang. Kraftstoffeinsparung durch Nutzung von Streckeninformationen, VDI-Berichte ; 2233 ; Seite 79-88, 2015.
- [6] C. Zhang, A. Vahidi, Route Preview in Energy Management of Plug-in Hybrid Vehicles, IEEE Transactions on Control Systems Technology, Volume: 20, Issue: 2, March 2012.
- [7] M. Schori ; T. J. Boehme ; B. Frank ; B. P. Lampe, Optimal Calibration of Map-Based Energy Management for Plug-In Parallel Hybrid Configurations: A Hybrid Optimal Control Approach, IEEE Transactions on Vehicular Technology, Volume: 64 , Issue: 9, Sept. 2015.
- [8] F. Töpfler, P. Antony, R. Kube, S. Köhle, Hybridbetriebsstrategien mit elektronischem Horizont - ein Gemeinschaftsprojekt der Daimler AG, der Volkswagen AG und dem ika, 17. Aachener Kolloquium Fahrzeug- und Motorentechnik, Aachen, Deutschland, 2008.

# **Elektrifizierung des Antriebsstrangs: Einsatz und Nutzen einer analytischen Radkraftverteilung in überaktuierten Elektrofahrzeugen**

**Dr.-Ing. Jan-Eric Moseberg,**  
Schaeffler Engineering GmbH, Nürnberg

## **Kurzfassung**

Neben der lokalen Reduktion von Schadstoffemissionen bietet die Elektrifizierung des Antriebsstrangs weitere Vorteile, welche aus der Verteilung des zentralen Antriebsaggregates auf vier radnahe Elektromotoren resultieren. Im Vergleich zu einem verbrennungsmotorisch betriebenen Fahrzeug ist ein solches Fahrzeug überaktuiert und besitzt somit eine erhöhte Anzahl an Stelleingriffen zur aktiven Beeinflussung der horizontalen Fahrzeugbewegung. Das vorgestellte Regelungskonzept nutzt diesen Umstand, um mittels Torque Vectoring ein gewünschtes längs- und querdynamisches Fahrverhalten zu realisieren, das mittels eingängiger Parameter verstellt und den Bedürfnissen des Fahrers angepasst werden kann. Des Weiteren ermöglicht die Überaktuierung eine Drehmomentverteilung, die zu einer Verringerung des maximalen Reifenkraftschlusses und damit zur Erhöhung der Fahrsicherheit führt.

## **1. Einleitung**

Bei der Elektrifizierung des Antriebsstrangs liegt das Hauptaugenmerk zumeist auf der lokalen Reduktion der Schadstoffemissionen von Kraftfahrzeugen. Durch die Verwendung von Elektromotoren lassen sich darüber hinaus aber auch anderweitige Optimierungsziele ins Auge fassen. Dies resultiert aus der Tatsache, dass Elektromotoren im Gegensatz zu Verbrennungskraftmaschinen kleiner fertigbar sind und dezentral im Fahrzeug untergebracht werden können. Während ein konventionelles Fahrzeug aus wirtschaftlichen und baulichen Gründen nur ein Antriebsaggregat an der Vorder- und/oder der Hinterachse besitzt, sind bei Elektrofahrzeugen vollkommen neue Fahrzeugarchitekturen mit mehreren Antriebseinheiten denkbar.

Im Allgemeinen umfasst die horizontale Fahrzeugbewegung die Längs-, Quer- und Gierbewegung. Ein konventionelles Fahrzeug ist folglich unteraktuiert, da den drei Bewegungsfreiheitsgraden nur zwei Stellgrößen in Form der Vorderachslenkung sowie der verbrennungsmotorisch angetriebenen Vorder- oder Hinterachse gegenüberstehen. Eine derartige Fahrzeugarchitektur ermöglicht daher in normalen Fahrsituationen zwar die Realisierung einer gewünschten Bahntrajektorie (Querbewegung) mit einer geforderten Fahrzeuggeschwindigkeit (Längsbewegung). Das Eigenlenkverhalten ist hingegen primär durch die Fahrzeuggeometrie und die

Bereifung festgelegt, da das Gierverhalten des Fahrzeugs nicht direkt und ohne Änderung der Längsbewegung beeinflusst werden kann.

Bei einem überaktuierten Fahrzeug mit jeweils einem Antriebs- und Lenkaggregat je Radeinheit lassen sich dagegen die Längs- und Querkräfte am Rad vollkommen unabhängig voneinander einstellen. In der Folge stehen insgesamt acht Stellgrößen zur Beeinflussung der drei Bewegungsgrößen der horizontalen Fahrzeuggbewegung zur Verfügung. Diese Redundanz lässt sich zum einen dazu nutzen, sekundäre Optimierungsziele anzustreben, wie z. B. die Maximierung der Fahrsicherheit oder die Erhöhung des Fahrkomforts. Zum anderen besteht die Möglichkeit, die funktionale Sicherheit des Gesamtsystems zu erhöhen, indem auf Aktor-ausfälle durch ein Umverteilen der Radkräfte reagiert wird.

Dieser Beitrag befasst sich mit der Ausnutzung dieser neuen, weitreichenden Möglichkeiten der Antriebsstrangelektrifizierung zur aktiven Beeinflussung der Horizontalbewegung eines überaktuierten Demonstratorfahrzeugs der Schaeffler Technologies AG & Co. KG. Dieses verfügt über vier radnahe elektrische Antriebseinheiten, sodass Antriebs- und Bremsmomente radindividuell verteilt werden können. Aufbauend auf universitären Forschungsergebnissen [1, 2] wird ein integriertes Fahrdynamikregelungskonzept für überaktuierte Elektrofahrzeuge hergeleitet, dessen modulare Architektur in Bild 1 dargestellt ist. Diese bietet den Vorteil, die Auslegung von Fahrzeuggwunschverhalten, die Verteilung der Drehmomente auf die Elektromotoren sowie die Stabilisierung von Fahrzeug- und Radbewegungen weitgehend unabhängig voneinander angehen und an die jeweilige Fahrzeugarchitektur anpassen zu können. Im vorliegenden Anwendungsfall dient der dargestellte Regelungsansatz primär der Erhöhung des Fahrspässes [3], indem das Fahrzeuggierverhalten den Wünschen des Fahrers entsprechend

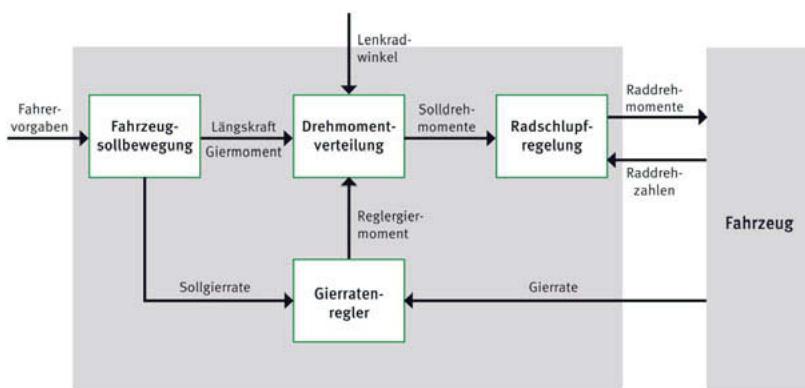


Bild 1: Architektur der Fahrdynamikregelung

eingestellt werden kann. Zusätzlich wird durch eine analytische Verringerung der Reifenkraftschlussausnutzungen aber auch eine Maximierung der Fahrsicherheit angestrebt, was zu einer unmittelbaren Vergrößerung des Bereichs der mit dem Fahrzeug realisierbaren Fahrmanöver führt.

Aufbauend auf dem in Abschnitt 2 zusammengefassten Fahrzeugmodell, wird in Abschnitt 3 zunächst aus dem Lenkradwinkel sowie der Fahr- und Bremspedalstellung eine Sollfahrzeugbewegung generiert. Unter Berücksichtigung der Reifenkraftschlussausnutzungen sowie der nicht beeinflussbaren Radseitenkräfte ermittelt Abschnitt 4 anschließend die zu dieser Sollbewegung führenden Sollradmomente. Die notwendigen Gierraten- und Radschlupfregelungen werden in Abschnitt 5 kurz zusammengefasst, bevor Abschnitt 6 das Konzept simulativ und experimentell validiert.

## 2. Fahrzeugmodell

Der Entwurf des vorgestellten Fahrdynamikregelungskonzeptes basiert auf einem nichtlinearen Zweispurmodell, welches die Zusammenhänge zwischen den Längs- und Querkräften am Rad sowie der horizontalen Fahrzeugbewegung in Form der Geschwindigkeit, des Schwimmwinkels und der Gierrate abbildet. Unter der Annahme, dass sich der Fahrzeugaufbau wie ein starrer Körper in der Ebene verhält, kann die Horizontalbewegung in einem fahrzeugfesten Koordinatensystem mit den Basisvektoren  $\underline{e}_x$  und  $\underline{e}_y$  beschrieben werden. Da das Fahrzeug um seine Hochachse gegenüber dem Inertialsystem mit der Gierrate  $\dot{\psi}$  rotiert, resultieren die Längs- und Querbeschleunigungen des Fahrzeugschwerpunktes

$$a_x = \dot{v}_x - v_y \dot{\psi} = \frac{F_x}{m}, \quad a_y = \dot{v}_y + v_x \dot{\psi} = \frac{F_y}{m}. \quad (1)$$

Hierin bezeichnen die Variablen  $v_x > 0$  und  $v_y$  die Längs- und die Quergeschwindigkeit im fahrzeugfesten Koordinatensystem. Auf den Fahrzeugschwerpunkt wirken gemäß Bild 2 die Längs- und Querkräfte  $F_x$  und  $F_y$  sowie das Giermoment  $M_z$ . Impuls- und Drallsatz liefern mit der Fahrzeuggmasse  $m$  sowie der Gierträgheit  $J_z$  die Differentialgleichungen der drei Freiheitsgrade der horizontalen Fahrzeugbewegung

$$\frac{d}{dt} \begin{bmatrix} v_x \\ v_y \\ \dot{\psi} \end{bmatrix} = \begin{bmatrix} v_x \dot{\psi} \\ -v_y \dot{\psi} \\ 0 \end{bmatrix} + \begin{bmatrix} \frac{1}{m} & 0 & 0 \\ 0 & \frac{1}{m} & 0 \\ 0 & 0 & \frac{1}{J_z} \end{bmatrix} \begin{bmatrix} F_x \\ F_y \\ M_z \end{bmatrix}. \quad (2)$$

Bei Vorwärtsfahrt berechnen sich die Fahrgeschwindigkeit und der Schwimmwinkel gemäß

$$v = \sqrt{v_x^2 + v_y^2}, \quad \beta = \arctan \frac{v_y}{v_x}. \quad (3)$$

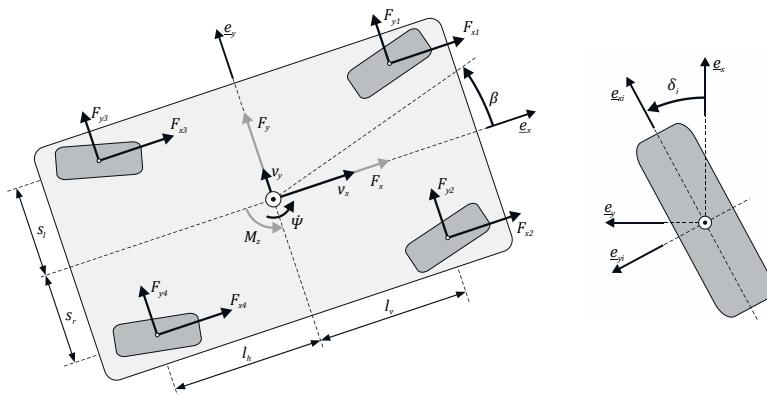


Bild 2: Fahrzeugabmessungen und Bewegungsgrößen der horizontalen Fahrzeubewegung sowie Zusammenhang zwischen Fahrzeug- und Radkoordinatensystem

Die Aufbaukräfte und das Giermoment in  $\underline{F}_H$  resultieren aus den acht Radkräfte  $\underline{F}_{xy} = [F_{x1} \ F_{y1} \ \dots \ F_{x4} \ F_{y4}]^T$  im fahrzeugfesten Koordinatensystem

$$\begin{bmatrix} F_x \\ F_y \\ M_z \end{bmatrix} = \underline{F}_H = \underbrace{\begin{bmatrix} 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 \\ -s_l & l_v & s_r & l_v & -s_l & -l_h & s_r & -l_h \end{bmatrix}}_{\underline{\mathcal{G}}} \underline{F}_{xy}. \quad (4)$$

Da die Vorderräder lenkbar sind, wird ein zusätzliches Radkoordinatensystem  $\{\underline{e}_{xi}, \underline{e}_{yi}\}$  im jeweiligen Radmittelpunkt eingeführt, welches gegenüber dem fahrzeugfesten Koordinatensystem um den Radlenkwinkel  $\delta_i$  verdreht ist (s. Bild 2). Die Abhängigkeiten zwischen Radkräften in Fahrzeug- und Radkoordinaten lauten

$$F_{xi} = \cos(\delta_i) F_{xi}^R - \sin(\delta_i) F_{yi}^R, \quad F_{yi} = \sin(\delta_i) F_{xi}^R + \cos(\delta_i) F_{yi}^R, \quad i = 1, 2. \quad (5)$$

### 3. Ermittlung der Fahrzeugsollbewegung

Das Vorsteuerungskonzept zur Ermittlung der Fahrzeugsollbewegung basiert auf der Annahme, dass der Lenkeinschlag an der Vorderachse die Fahrzeugquerbeschleunigung festlegt. Die Drehmomente der vier radnahen Elektroantriebe wirken sich hingegen nur auf die Längsbeschleunigung und die Gierrate des Fahrzeugs aus. Entwurfsziel des Fahrzeugsollverhaltens ist es folglich, Sollverläufe für diese beiden verbleibenden Freiheitsgrade der horizontalen Fahrzeubewegung zu ermitteln und dabei physikalische und technische Restriktionen wie das maximale Gesamtmoment der Antriebeinheiten zu berücksichtigen. Hierbei fließen

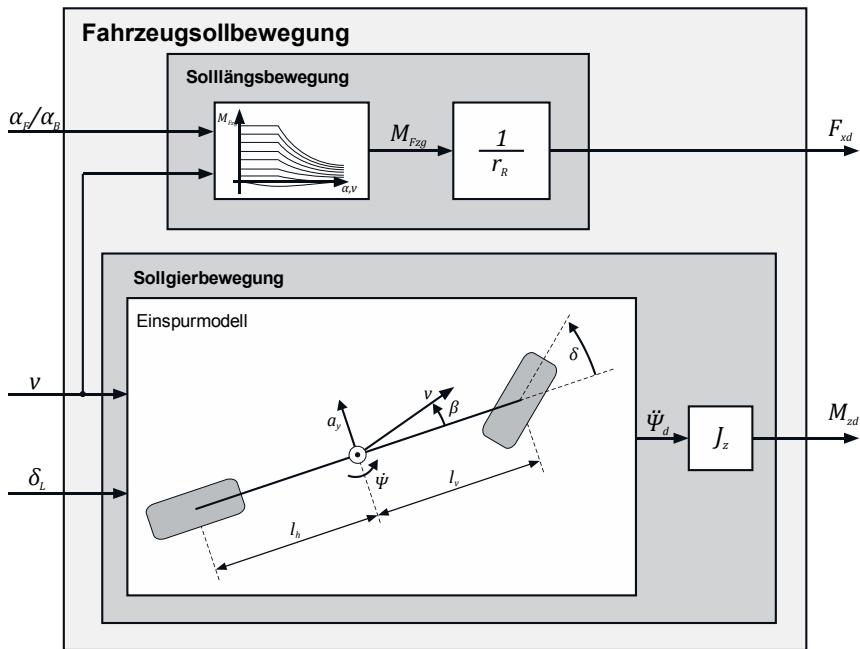


Bild 3: Ermittlung von Sollängskraft und Sollgiermoment

lediglich die Zusammenhänge zwischen den Fahrervorgaben (Lenkradwinkel sowie Brems- und Fahrpedalstellung) und der horizontalen Fahrzeugaufbaubewegung ein. Die tatsächliche Verteilung der Aktoren auf das Fahrzeug wird an dieser Stelle nicht berücksichtigt, sondern ist erst für den Entwurf der Drehmomentverteilung relevant. Dies bewirkt eine relativ freie Vorgabe und Parametrierung der Sollfahrzeugbewegung.

Der obere Teil von Bild 3 fasst die Strategie zur Generierung einer fahrzeugbezogenen Sollängskraft  $F_{xd}$  zusammen. Hauptbestandteil ist ein applizierbares Kennfeld, das ein vom Fahr- und Bremspedal sowie der Fahrzeuggeschwindigkeit abhängiges Gesamtdrehmoment ermittelt. Hier besteht die Möglichkeit, ein virtuelles Schleppmoment oder ein aufgrund des Feldschwächebereichs der Elektroantriebe abfallendes Maximaldrehmoment zu berücksichtigen. Das resultierende Gesamtdrehmoment wird anschließend in die Sollängskraft  $F_{xd}$  umgerechnet, die dann Eingangsgröße der Drehmomentverteilung ist.

Die Erzeugung des Sollgiermoments basiert auf dem bekannten Einspurmodell [4], welches in Bild 3 unten dargestellt ist. Zwischen den Schräglaufrückwinkeln der Räder und den resultierenden Seitenkräften wird an dieser Stelle ein linearer Zusammenhang mit den vorderen und hinteren

Schräglaufstiegssteifigkeiten  $c_v$  und  $c_h$  herangezogen. Mit der Lenkübersetzung  $i_L$  führt dies zu den Differentialgleichungen des Einspurmodells für dessen Schwimmwinkel  $\beta$  und Gierrate  $\dot{\psi}$

$$\begin{bmatrix} \dot{\beta} \\ \ddot{\psi} \end{bmatrix} = \begin{bmatrix} -\frac{c_v + c_h}{mv} & -\left(1 + \frac{c_v l_v - c_h l_h}{mv^2}\right) \\ -\frac{c_v l_v - c_h l_h}{J_z} & -\frac{c_v l_v^2 + c_h l_h^2}{J_z v} \end{bmatrix} \begin{bmatrix} \beta \\ \psi \end{bmatrix} + \begin{bmatrix} \frac{c_v i_L}{mv} \\ \frac{c_v l_v i_L}{J_z} \end{bmatrix} \delta_L. \quad (6)$$

Es sei an dieser Stelle betont, dass die Parameter in Gleichung (6) nicht mit denen des realen Fahrzeugs übereinstimmen müssen. Vielmehr werden sie dafür verwendet, das gewünschte Übertragungsverhalten der Gierrate zu parametrieren. Stimmen sie nicht mit den realen Parametern überein, müssen die vier radnahen Elektromotoren einen zusätzlichen Giermomentanteil erzeugen, um Abweichungen zu kompensieren. So lässt sich der Eigenlenkgradient

$$EG = \frac{m}{l_v + l_h} \left( \frac{l_h}{c_v} - \frac{l_v}{c_h} \right) \quad (7)$$

mittels der virtuellen Fahrzeugparameter und Reifensteifigkeiten relativ beliebig einstellen. Dies kann beispielsweise ein übersteuerndes Verhalten ( $EG > 0$ ) hervorrufen, obwohl das Fahrzeug eigentlich untersteuernd ( $EG < 0$ ) ausgelegt wurde. Das hierfür notwendige Sollgiermoment  $M_{zd}$  wird unter Berücksichtigung der realen Gierträgheit des Fahrzeugs aus der Sollgierrate ermittelt und dient als weitere Eingangsgröße der Radmomentenverteilung.

#### 4. Analytische Radmomentenverteilung

Die sich anschließende Drehmomentverteilung bestimmt die Solldrehmomente der vier Elektromotoren, welche für die Realisierung von Sollängskraft und Sollgiermoment notwendig sind. Im Zuge dessen wird nicht nur der Einfluss der Radseitenkräfte auf Längs- und Gierbewegung kompensiert, sondern auch das Kraftschlusspotential zwischen Reifen und Fahrbahn im Sinne einer Fahrsicherheitsmaximierung bestmöglich ausgenutzt. Um dies zu erreichen, ermittelt die Radmomentenverteilung zunächst Radlängskräfte und rechnet diese dann in entsprechende Solldrehmomente für die vier Radantriebe um.

Während die Fahzeugquerkraft  $F_y$  vorwiegend durch die Radseitenkräfte  $F_{yi}^R$  bestimmt ist, hängen die fahrzeugbezogene Längskraft  $F_x$  sowie das Giermoment  $M_z$  hauptsächlich von den Radlängskräften  $F_{xi}^R$  ab. Unter diesen Annahmen folgt durch Zusammenfassung der Gleichungen (4) und (5) die Grundgleichung für den Entwurf der Radmomentenverteilung

$$\begin{bmatrix} F_{xd} \\ M_{zd} \\ \underline{F}_{Hd} \end{bmatrix} - \underbrace{\begin{bmatrix} -\sin \delta_1 & -\sin \delta_2 & 0 & 0 \\ s_l \sin \delta_1 + l_v \cos \delta_1 & -s_r \sin \delta_2 + l_v \cos \delta_2 & -l_h & -l_h \\ \underline{G}_y \end{bmatrix}}_{\underline{G}_y} \begin{bmatrix} F_{y1}^R \\ F_{y2}^R \\ F_{y3}^R \\ F_{y4}^R \end{bmatrix} = \underbrace{\begin{bmatrix} F_{x1}^R \\ F_{x2}^R \\ F_{x3}^R \\ F_{x4}^R \end{bmatrix}}_{\underline{F}_x^R} \quad (8)$$

$$\underbrace{\begin{bmatrix} \cos \delta_1 & \cos \delta_2 & 1 & 1 \\ -s_l \cos \delta_1 + l_v \sin \delta_1 & s_r \cos \delta_2 + l_v \sin \delta_2 & -s_l & s_r \\ \underline{G}_x \end{bmatrix}}_{\underline{G}_x} \cdot$$

Die beiden Terme auf der linken Seite von Gleichung (8) resultieren aus der Vorsteuerung und dem durch den Fahrer vorgegebenen Lenkradwinkel. Ihre Differenz kann als Abweichung des gewünschten vom inhärenten Fahrzeugverhalten interpretiert werden, die eine geeignete Verteilung der Radlängskräfte  $F_{xid}^R$  ausgleichen soll.

Aufgrund der Überaktuierung des Fahrzeugs ist das Gleichungssystem (8) unterbestimmt, was nach [5] ein Problem der Control Allocation mit mehreren Lösungen darstellt. Die Drehmomentverteilung strebt eine fahrsicherheitsmaximierte Lösung an, die auf der allgemeinen Lösung der Gleichung (8) nach den Radlängskräften basiert

$$\underline{F}_x^R = \underline{G}_x^+ \left( \underline{F}_{Hd} - \underline{G}_y \underline{F}_y^R \right) + \underline{G}_x^\perp \underline{\Delta F}_x \quad (9)$$

Hierin bezeichnet  $\underline{G}_x^+ = \underline{G}_x^T \left( \underline{G}_x \underline{G}_x^T \right)^{-1}$  die Moore-Penrose-Inverse und  $\underline{G}_x^\perp$  den Rechtsannihilator von  $\underline{G}_x$ . Es gilt  $\underline{G}_x \underline{G}_x^\perp = \underline{0}$ , wodurch die frei wählbaren Längskraftparameter  $\underline{\Delta F}_x$  keinen Einfluss auf die Fahrzeugbewegung haben. Nichtdestotrotz wirken sie sich auf die Radlängskräfte  $\underline{F}_x^R$  aus, was die Erhöhung der Fahrsicherheit bei gleichzeitiger Umsetzung der gewünschten Fahrzeugbewegung ermöglicht.

Die Fahrsicherheit ist quantifizierbar durch die Kraftschlussausnutzung der Reifen gemäß

$$\eta_i = \frac{\sqrt{F_{xi}^{R^2} + F_{yi}^{R^2}}}{F_{max i}}, \quad i = 1 \dots 4. \quad (10)$$

Die Ausnutzung beschreibt das Verhältnis zwischen den geforderten und den maximal möglichen Radkräften an der Kraftschlussgrenze, die von der Radlast und der Reibung zwischen Reifen und Fahrbahn abhängen. Dementsprechend basiert die Kostenfunktion der Drehmomentverteilung auf der gewichteten Quadratsumme der vier Kraftschlussausnutzungen:

$$\sum_{i=1}^4 q_i \eta_i^2 = \sum_{i=1}^4 q_i \frac{F_{xi}^{R^2} + F_{yi}^{R^2}}{F_{max i}^2} = \sum_{i=1}^4 q_i \frac{F_{xi}^{R^2}}{F_{max i}^2} + \sum_{i=1}^4 q_i \frac{F_{yi}^{R^2}}{F_{max i}^2} \quad (11)$$

Wie bereits erwähnt, hängen die Radseitenkräfte vom Lenkwinkel ab und führen somit zu einem unbeeinflussbaren zweiten Summanden in Gleichung (11). In Übereinstimmung mit dem Kamm'schen Kreis [4] verbleibt lediglich die Differenz zwischen dem Quadrat der Maximalkräfte und dem Quadrat der Radseitenkräfte zur Realisierung der Radlängskräfte. Bei entsprechender Wahl der Gewichtungskoeffizienten  $q_i$  lautet die verwendete Kostenfunktion

$$J = \sum_{i=1}^4 \frac{F_{xi}^R}{F_{maxi}^2 - F_{yi}^R} \quad (12)$$

Eine Minimierung von  $J$  nach den frei wählbaren Längskraftparametern  $\Delta F_x$  verringert die größte der vier Kraftschlussausnutzungen  $\eta_i$  und führt somit zu etwa gleich großen Ausnutzungen an den vier Rädern. Nach [6] vermeidet dies Instabilität und erhöht die Fahrsicherheit. Da die Minimierung von  $J$  analytisch erfolgt, ist der benötigte Rechenaufwand verglichen mit dem Algorithmus zur Erreichung des fahrdynamischen Optimums in [7] gering. Aus den resultierenden Radkräften werden unter Berücksichtigung von Radhalbmesser und Getriebeübersetzung schließlich die Sollradmomente der vier Antriebsmotoren ermittelt. Das Ergebnis ist eine echtzeitfähige Drehmomentverteilung, die bei Realisierung des gewünschten fahrdynamischen Verhaltens gleichzeitig die Fahrsicherheit erhöht.

## 5. Gierraten- und Radschlupfregelung

Die Sollradmomente werden anschließend an die elektrischen Antriebseinheiten übermittelt und, falls physikalisch möglich, realisiert. Kommt es dabei zu einem Durchdrehen oder Blockieren eines Rades, verringert die Radschlupfregelung dessen Drehmomentbetrag, um so die Bewegung zu stabilisieren.

Eine übergeordnete Gierratenregelung ergänzt die bis hierhin vorgestellte Vorsteuerungsstruktur. Ein parameteradaptives Regelungskonzept vermeidet hierbei Eingriffe in normalen Fahrsituationen, um ein reproduzierbares und vorsehbares Fahrzeugverhalten zu gewährleisten. Wird hingegen ein kritisches Fahrmanöver detektiert, stabilisiert die Regelung die Gierrbewegung, indem sie einen zusätzlichen Giermomentanteil erzeugt, der die Einhaltung des Sollgierverhaltens sicherstellt.

## 6. Validierung

Abschließend sollen die Vorteile des vorgestellten Regelungskonzeptes simulativ und experimentell herausgestellt werden. Hierfür wird zunächst die Drehmomentverteilung mit einem einfacheren Verteilungsalgorithmus verglichen, welcher lediglich die Moore-Penrose-Inverse

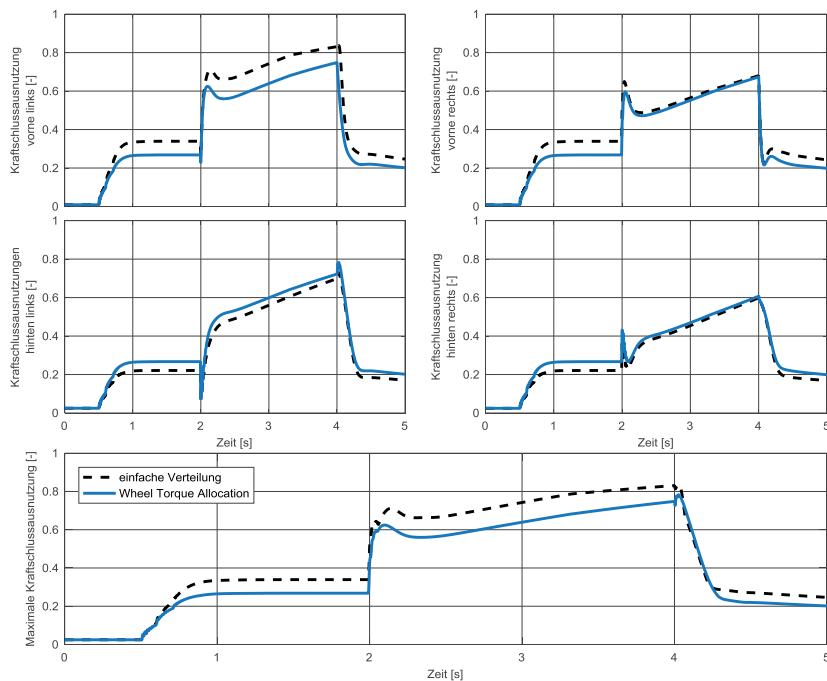


Bild 4: Kraftschlussausnutzungen der vier Reifen sowie ihr Maximalwert bei Spurwechsel

nicht aber die frei vorgebbaren Längskraftparameter verwendet. In der Folge erfahren die unterschiedlichen Radlasten bei der Verteilung keine Berücksichtigung, was zu fast identischen Drehmomenten an Vorder- und Hinterachse führt. Die Validierung geschieht anhand eines simulierten Spurwechsels mit einer Längsbeschleunigung von ca.  $3 \text{m/s}^2$  zwischen  $t = 0,5\text{s}$  und  $t = 5\text{s}$  sowie einem Lenkradwinkel von  $45^\circ$  zwischen  $t = 2\text{s}$  und  $t = 4\text{s}$ , der zu einer Querbeschleunigung von  $6\text{m/s}^2$  führt. Bild 4 zeigt die resultierenden Kraftschlussausnutzungen der vier Reifen sowie ihren Maximalwert für die vorgestellte Drehmomentverteilung und den einfacheren Verteilungsalgorithmus. Beide Fahrzeugkonfigurationen kommen der Kraftschlussgrenze während dieses Fahrmanövers sehr nah. Dabei ist die vorgestellte Drehmomentverteilung in der Lage, die maximale Kraftschlussausnutzung gegenüber dem einfachen Algorithmus um bis zu 10% zu reduzieren. Dies führt zu einer entsprechenden Erhöhung der Fairsicherheit und erweitert den Bereich der umsetzbaren Fahrmanöver.

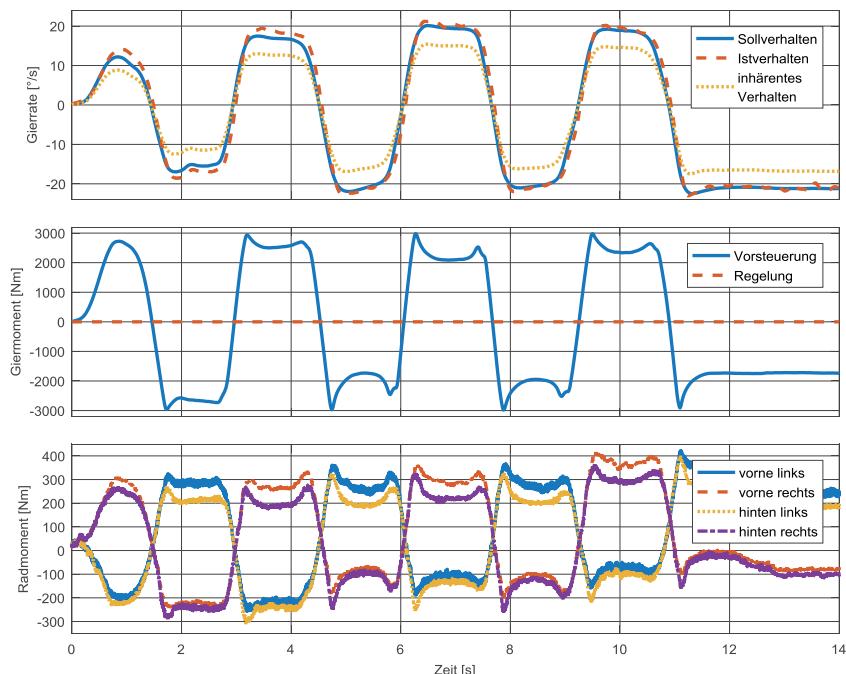


Bild 5: Gierrate, Giermoment und Radmomente bei moderater, ungeregelter Slalomfahrt

Überdies wurde das vorgestellte Regelungskonzept im Demonstratorfahrzeug "Schaeffler 4ePerformance" der Schaeffler Technologies AG & Co. KG validiert. Der Antrieb dieses Fahrzeugs besteht aus vier Elektromotoren der Formula E Saison 2016/17 mit jeweils 220kW und 320Nm Spitzennmoment. Jeder Motor ist radnah im Fahrzeug verbaut und mittels eigenem Stirnradgetriebe direkt mit dem jeweiligen Rad verbunden, was eine radindividuelle Drehmomentvorgabe ermöglicht. Zwei Batterien stellen eine Gesamtenergie von 64kWh zur Verfügung. Als Vehicle Control Unit kommt die flexibel konfigurierbare Echtzeitprozessoreinheit PROTroniC Topline mit Dual-PowerPC Architektur der Schaeffler Engineering GmbH zum Einsatz. Bei diesem Rapid Control Prototyping Steuergerät übernimmt ein Freescale PowerPC mit 1 GHz Rechenleistung und Double Precision Floating Point exklusiv die Verarbeitung der Anwendungssoftware, während ein zweiter Prozessor den Hauptprozessor von allen Peripherie- und Kommunikationsaufgaben entlastet.

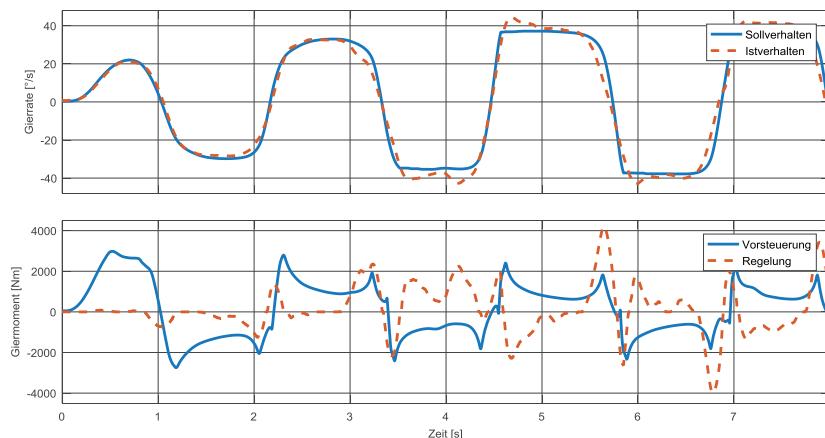


Bild 6: Gierrate und Giermoment bei geregelter Slalomfahrt an der fahrdynamischen Grenze

Durch Fahrzeugabmessung, Gewichtsverteilung und Bereifung neigt das Fahrzeug eigentlich zu einem leicht untersteuernden Verhalten. Die vorgestellte Regelungsstruktur ermöglicht jedoch eine Veränderung des Fahrverhaltens entsprechend dem Fahrerwunsch, was im Folgenden zu einem einstellbaren, übersteuernden Eigenlenkverhalten führt. Zur Veranschaulichung der Leistungsfähigkeit des Vorsteuerungskonzepts wird zunächst ein Open-loop-Slalommanöver mit deaktivierter Gierratenregelung betrachtet. Die Lenkradwinkelamplitude beträgt hierbei ca. 45° bei einer Fahrzeuggeschwindigkeit von etwa 70km/h. In dieser Fahrsituation befinden sich die Reifen im linearen Teil der Kraft-Schlupf-Kennung, was dem Einspurmodell der Vorsteuerung entspricht. Bild 5 zeigt die Gierrate, das Giermoment sowie die Drehmomente an den vier Rädern. Obwohl das inhärente Fahrzeugverhalten untersteuernd ist, entspricht die tatsächliche Gierrate annähernd exakt der Sollgierrate, welche aus einer übersteuernden Parametrierung der Vorsteuerung resultiert. Mithin ist das vorgestellte Torque-Vectoring-Konzept durch geeignete Drehmomentverteilung sogar ohne Reglereingriff in der Lage, die Überaktuierung des Fahrzeugs zur Umsetzung eines gewünschten Eigenlenkverhaltens zu nutzen. Abschließend wird ein dynamischeres Slalommanöver mit aktiver Gierratenregelung betrachtet. Bei einer Fahrzeuggeschwindigkeit von etwa 60km/h beträgt die Lenkradwinkelamplitude hier nahezu 100°. Ohne Reglereingriff wäre das Fahrzeug übersteuernder als gewünscht und würde sogar zu Instabilität tendieren. Wie Bild 6 veranschaulicht, folgt das Fahrzeug der Sollgierrate jedoch recht gut. Indem die Gierratenregelung das Giermoment reduziert, stabilisiert sie die Fahrzeuggbewegung und wirkt dem Übersteuern entgegen. Die Überaktuierung des

Fahrzeugs dient somit nicht nur der Einstellung eines gewünschten Eigenlenkverhaltens, sondern vermag zudem, die Fahrzeuggbewegung in kritischen Situationen zu stabilisieren.

## 7. Zusammenfassung

In diesem Beitrag wurde ein Regelungskonzept für überaktivierte Fahrzeuge mit radnahen Antriebsaggregaten vorgestellt. Dieser Fahrzeugtypus ermöglicht die Anpassung des Eigenlenkverhaltens gemäß dem Fahrerwunsch. Hierfür wurde zunächst eine Vorsteuerung sowie eine echtzeitfähige Drehmomentverteilung hergeleitet, welche zudem die Fahrsicherheit erhöht. Nachdem kurz auf die zusätzlich notwendigen Regelungsstrukturen für Radschlupf und Gierrate eingegangen wurde, konnte die Leistungsfähigkeit des Regelungskonzeptes sowohl simulativ als auch experimentell demonstriert werden.

Das vorgestellte Konzept hat zwei große Vorteile. Es ermöglicht dem Fahrer eine auf seine Bedürfnisse angepasste Einstellung von Längs- und Gierverhalten des Fahrzeugs und vermag somit, den Fahrspaß zu erhöhen. Außerdem reduziert es die Kraftschlussausnutzungen der Reifen, was die Fahrsicherheit verbessert und den Bereich möglicher Fahrmanöver erweitert.

## 8. Literatur

- [1] Moseberg, J.-E.; Roppenecker, G.: Eine kaskadierte Regelung der horizontalen Fahrzeuggbewegung mit Einzelradaktorik. VDI-Berichte Nr. 2233 – AUTOREG 2015, S. 67-78. Düsseldorf: VDI Verlag GmbH, 2015
- [2] Moseberg, J.-E.: Regelung der Horizontalbewegung eines überaktuierten Fahrzeugs unter Berücksichtigung von Realisierungsanforderungen. Erlangen: FAU University Press 2016
- [3] Moseberg, J.-E.; Kohlhoff, J.: Electric all wheel drive: How to make use of the over-actuation of electrified vehicles. E-MOTIVE – 10. Expertenforum Elektrische Fahrzeugantriebe, Stuttgart 2018
- [4] Mitschke, M.; Wallentowitz, H.: Dynamik der Kraftfahrzeuge. Wiesbaden: Springer Fachmedien 2014
- [5] Johansen, T.A.; Fossen, T.I.: Control Allocation – A Survey. Automatica 49 (2013), 1087-1103
- [6] Knobel, Ch.; Pruckner, A.; Bünte, T.: Optimized Force Allocation – A General Approach to Control and to Investigate the Motion of Over-Actuated Vehicles. Proc. of the 4<sup>th</sup> IFAC Symposium on Mechatronic Systems, 2006, 366-371
- [7] Orend, R.: Integrierte Fahrdynamikregelung mit Einzelradaktorik – Ein Konzept zur Darstellung des fahrdynamischen Optimums. Aachen: Shaker Verlag 2007

# Optimalsteuerung des Energieflusses in einem 48V-Bordnetz schwerer Nutzfahrzeuge

M.Sc. **Matthias Dellermann**, Dr.-Ing. **Ottmar Gehring**,  
Daimler AG, Stuttgart;  
Prof. Dr.-Ing. **Oliver Zirn**,  
Fakultät Fahrzeugtechnik, Hochschule Esslingen

## Kurzfassung

Vorausschauende Betriebsstrategien für Hybridfahrzeuge sind heute Stand der Technik. In diesem Beitrag, wird eine optimale Betriebsstrategie am Beispiel eines 48V-Bordnetzes im LKW bestimmt und ein ganzheitlicher Ansatz vorgestellt, wobei die Energieversorgung elektrifizierter Nebenverbraucher gemeinsam mit klassischen Hybridfunktionen prädiktiv gesteuert wird. Die Funktionen und Effekte der optimalen Steuerung des Bordnetzes werden vorgestellt und mit einem konventionellen, nicht-vorausschauenden Ansatz verglichen. Es wird gezeigt, dass sich durch die vorausschauende Steuerung des 48V-Bordnetzes zusammen mit dem gekoppelten 24V-Netz ein zusätzliches Potential zur Kraftstoffeinsparung ergibt.

## 1. Einleitung

Die fortschreitende Steigerung der Kraftstoffeffizienz von LKW im Fernverkehr rückt verstärkt Technologien in den Fokus der Nutzfahrzeugbranche, die über eine weitere Optimierung des Verbrennungsmotors (VM) hinausgehen. Wie in [1] und [2] beschrieben, kann eine zusätzliche Hybridisierung des Antriebsstrangs weitere Einsparungen beim Dieserverbrauch und somit bei den Emissionen ermöglichen. Systeme basierend auf einer Spannungslage von 48V sind weit verbreitet und übernehmen neben der Bereitstellung von ausreichender Leistung für Komfort- und Entertainmentsysteme immer weitere Funktionen zur Kraftstoffeinsparung, was für den PKW-Bereich in [3] betrachtet ist. So ist es aus der allgemeinen Diskussion um 48V heraus naheliegend, auch im Nutzfahrzeubereich ein solches System zu untersuchen. Die Verzögerungsenergie der langen Bremsphasen während Bergabfahrten bei schweren Nutzfahrzeugen im Fernverkehr kann durch eine elektrische Maschine (EM) zurückgewonnen werden und entweder in einer Batterie gespeichert oder direkt elektrisch verbraucht werden. Gespeicherte Energie kann zu einem späteren Zeitpunkt wieder an den Antriebsstrang abgegeben werden. Wobei direkt in einem elektrifizierten Nebenverbraucher eingesetzte Energie effizienter genutzt wird, da eine wirkungsgradbehaftete Zwischenspeicherung in der Batterie nicht nötig ist.

Folglich ist es bei einem Hybridfahrzeug mit der Spannungslage von 48V sinnvoll, elektrische Verbraucher dieser Spannungslage an Bord zu haben, um einerseits die elektrische Energie optimal zu nutzen [4] und um andererseits die Last des VM weiter zu reduzieren. Denn diese elektrifizierten Aggregate können bedarfsgerecht, drehzahlunabhängig vom VM und im Idealfall durch rekuperierte Energie betrieben werden. In Bild 1 ist das Ersatzschaltbild des Mehrspannungsnetzes eines LKW dargestellt. Das klassische 24V-Bordnetz bleibt zusammen mit der Blei-Säure-Batterie vorhanden. Lediglich der 24V-Generator wird durch einen DCDC-Wandler ersetzt, der das 24V-Netz aus dem 48V-Bordnetz versorgt, wobei ein Energiefluss in beide Richtungen nicht ausgeschlossen werden soll. Das 24V-Netz kann sowohl als Energiequelle als auch als Energiesenke für die 48V-Seite fungieren. Auf dieser ist eine Lithium-Ionen-Batterie mit hoher Zyklusfestigkeit installiert, um möglichst dynamisch rekuperierte Energie aufzunehmen und abzugeben.

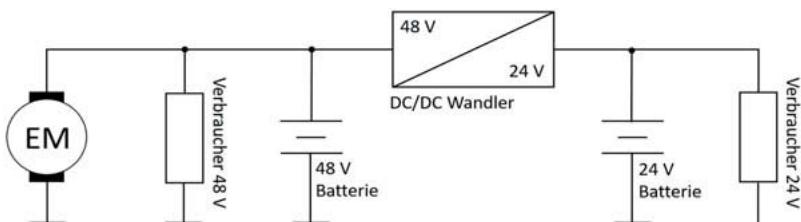


Bild 1: Architektur eines 48V/24V-Mehrspannungsnetzes

Als weiterer Vorteil der Entkopplung von VM und Nebenverbrauchern durch deren Elektrifizierung ist zu nennen, dass in einigen Fahrsituationen der VM abgestellt werden kann, ohne die Fahrfunktionen des LKW zu beeinträchtigen. Während dieses sog. Segelns kann z.B. die Motorkühlung sichergestellt werden, da eine elektrifizierte Wasserpumpe aus den beiden Bordnetzen redundant versorgt werden kann. Besonders für diese Segelphasen ist eine vorausschauende Betriebsstrategie notwendig, um zu entscheiden, ob es sich lohnt den VM abzustellen. Weiterhin kann durch die Prädiktion die installierte Batteriekapazität im System und damit die Anschaffungskosten reduziert werden. Wird der Ladezustand der Batterie vorausschauend geplant, können Betriebsgrenzen besser eingehalten werden, was sich positiv auf die Lebensdauer auswirkt und es kann sichergestellt werden, dass der Energiespeicher nicht voll ist, wenn gerade durch Rekuperation zusätzliche elektrische Energie gewonnen werden kann. Aus diesen Gründen wird in der vorliegenden Arbeit aufsetzend auf dem vorausschauenden Tempomaten eines Fernverkehrs-LKW eine prädiktive Betriebsstrategie entwickelt, welche nicht nur die Hybridfunktionen, sondern auch das Bordnetz steuert. Anhand von simulierten Drehzahl- und Drehmomentverläufen wird die Strecke in heuristische Anwendungsfälle

(sog. *Use Cases*) unterteilt. Wie auch in [5], wird über diese Abschnitte der Ladezustand der Batterie optimal geplant, woraus sich eine Steuertrajektorie für EM und Nebenverbraucher ergibt.

Um sämtliche Hybridfunktionen realisieren zu können eignet sich eine P2-Hybridkonfiguration, wobei die EM mechanisch zwischen Kupplung und Getriebe angreift. Somit kann sowohl bei abgestelltem VM und geöffneter Kupplung elektrisch gefahren, gerollt oder rekuperiert werden, als auch im Stand durch den VM und die EM die Batterie geladen werden, indem das Getriebe neutral geschalten wird. Die im vorliegenden Beitrag betrachtete Hybridarchitektur ist in Bild 2 dargestellt, wobei die EM am Nebenabtrieb des Antriebsstrangs installiert ist. Abgesehen vom Wirkungsgrad des Nebenabtriebs  $\eta_{PTO}$ , entspricht dies physikalisch der geschilderten Position zwischen Getriebe und Kupplung.

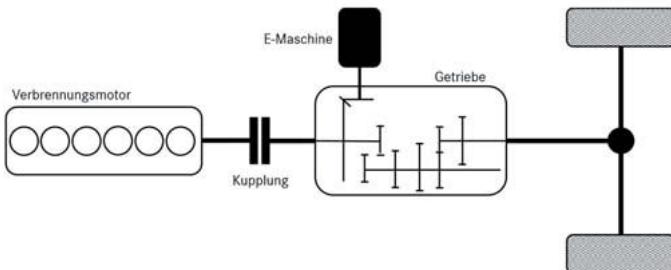


Bild 2: Schema des betrachteten Antriebsstrangs

## 2. Fahrzeugmodell zur Kraftstoffverbrauchsberechnung

Um den Einfluss einer vorausschauenden Betriebsstrategie des 48V-Hybrids auf den Kraftstoffverbrauch zu evaluieren, wird zur Simulation und Optimierung ein mathematisches Modell des Fahrzeugs erstellt. Es wird angenommen, dass die Längsdynamik für einen Fernverkehrs-LKW nach heutigem Stand der Technik durch bereits existente und erprobte prädiktive Strategien, wie sie beispielsweise in [6] entwickelt werden, bestmöglich geplant und eingeregelt wird. Daher gilt im Rahmen dieser Arbeit die Prämisse, dass die Längsdynamik nicht beeinflusst wird. Somit wird darauf verzichtet, ein dynamisches Modell des Gesamtfahrzeugs zu simulieren. Folglich muss das Getriebeausgangsmoment denselben zeitlichen Verlauf aufweisen wie vom prädiktiven Tempomaten gemäß [6] gefordert, unabhängig davon, ob das Fahrzeugmodell 48V-Komponenten besitzt. Als Eingangsdaten für das Modell dienen hier Software-in-the-Loop-basierte Simulationsergebnisse. Zur Simulation des Einflusses des 48V-Systems auf den Kraftstoffverbrauch eines LKW werden zusätzliche elektromotorische Mo-

mente  $M_{EM}$  unter Berücksichtigung von  $\eta_{PTO}$  vom ursprünglich zum Vortrieb geforderten Moment  $M_{req}$  des VM abgezogen. Dieser wird dadurch entlastet und muss ein geringeres resultierendes Moment abgeben, um die geforderte Geschwindigkeit des LKW beizubehalten. Mit diesem neuen resultierenden Moment des Verbrennungsmotors

$$M_{VM, res} = M_{req} - \eta_{PTO} M_{EM} \quad (1)$$

wird zusammen mit der momentanen Drehzahl des Motors der aktuelle Kraftstoffverbrauch anhand eines Kennfeldes bestimmt. Die Vorzeichen der Momente sind so gewählt, dass den Antriebsstrang bremsende Größen negativ gezählt werden.

Das dynamische Verhalten des elektrischen Bordnetzes aus Bild 1 wird für die folgende Optimierung zeitdiskret modelliert. Der Ladezustand  $x_{SOC48}$  der 48V-Batterie zum Zeitschritt  $k$  wird durch die Differenzengleichung

$$x_{SOC48}[k+1] = \Delta x_{SOC48}[k] + x_{SOC48}[k] = -\frac{I_{bat48}[k]}{Q_{bat48}} T_S + x_{SOC48}[k] \quad (2)$$

mit Schrittweite  $T_S$  beschrieben, wobei  $I_{bat48}$  und  $Q_{bat48}$  jeweils den Strom und die speicherbare Ladung der Batterie bezeichnen. Für eine einfachere Lesbarkeit wird im Folgenden auf die Zeitabhängigkeit in der Notation verzichtet. Der Batteriestrom  $I_{bat48}$  wird gemäß eines Thévenin-Ersatzschaltbildes einer idealen Spannungsquelle mit Leerlaufspannung  $U_{OC}$  und Innenwiderstand  $R_{int}$  nach

$$I_{bat48} = \frac{1}{2R_{int}} \left( U_{OC} - \sqrt{U_{OC}^2 - 4 R_{int} P_{bat48}} \right) \quad (3)$$

berechnet und hängt von der elektrischen Leistung  $P_{bat48}$  ab, mit welcher die Batterie beaufschlagt wird. In Anlehnung an [7] laden negative Ströme die Batterie. Die Leerlaufspannung und der Innenwiderstand werden aus Kennfeldern bestimmt und hängen vom momentanen Ladezustand  $x_{SOC48}$  ab. Eine Temperaturabhängigkeit ist hier unter der Annahme vernachlässigt, dass ein geeignetes Kühlssystem die Batterie in einem konstanten Betriebsfenster hält, in dem der Einfluss der Temperaturänderung auf die beiden Parameter gering ist. Mit den Gleichungen (2) und (3) und entsprechend angepassten Parametern ist die 24V-Batterie auf die gleiche Weise modelliert.

Der bereits erwähnte DCDC-Wandler ist als Proportionalglied mit einem konstanten Wirkungsgrad  $\eta_{DCDC}$  beschrieben. Über einen Parameter  $r_{DCDC} \in [-1, 1]$  wird der Energiefluss von einer Spannungsebene zur anderen gesteuert, indem die maximale Leistung  $P_{DCDC,max}$  des DCDC-Wandlers auf der Versorgerseite entsprechend skaliert wird. Für Werte von  $r_{DCDC} > 0$  stellt sich eine Leistungsverteilung

$$P_{DCDC48} = r_{DCDC} P_{DCDC,max} \quad (4)$$

$$P_{DCDC24} = \eta_{DCDC} P_{DCDC48} \quad (5)$$

von der 48V- zur 24V-Seite ein. Analog dazu bewirkt ein negativer Wert von  $r_{DCDC}$  eine Übertragung in umgekehrter Richtung. Weitere elektrifizierte Nebenverbraucher beider Spannungslagen sind durch zeitlich konstante Mittelwerte angenähert. Die Leistungsbilanz auf der 48V-Seite ergibt für die benötigte Leistung  $P_{EM,el}$  der EM

$$P_{EM,el} = P_{bat48} - P_{aux48} - P_{DCDC48} \quad (6)$$

mit der gewünschten Leistung der Lithium-Ionen-Batterie, der Summe der Leistungen aller Nebenverbraucher  $P_{aux48}$  im 48V-Bordnetz und der Leistung, die nach Gleichung (4) über den DCDC-Wandler fließt. Der Wirkungsgrad der EM  $\eta_{EM}$  wird betriebspunktabhängig anhand eines repräsentativen Kennfeldes bestimmt, das sich gut mit verschiedenen Herstellerangaben deckt. Es resultiert wegen des Verbrauchskennfelds  $\dot{m}_{fuel}(\omega, M)$  ein nichtlineares System mit den beiden SOC-Werten der Batterien als Zustände

$$x_1 = x_{SOC48} \quad (7)$$

$$x_2 = x_{SOC24} \quad (8)$$

und den beiden Steuergrößen

$$u_1 = \Delta x_{SOC48} \quad (9)$$

$$u_2 = r_{DCDC} \cdot \quad (10)$$

### 3. Unterteilung des Fahrzyklus in heuristische Abschnitte

Der betrachtete Fahrzyklus besitzt die Gesamtdauer  $T_{Zyklus}$ . Um den Rechenaufwand für den Optimierungsalgorithmus zu reduzieren, soll nicht jeder einzelne diskretisierte Zeitschritt betrachtet werden, sondern es wird die Fahrstrecke im Vorfeld in heuristisch klassifizierte Segmente unterteilt. Diese sogenannten „Use Cases“  $UC_i = 1, 2, \dots, N_{UC}$  haben jeweils eine zeitliche Länge  $\Delta t_i$ , so dass

$$\sum_{i=1}^{N_{UC}} \Delta t_i = T_{Zyklus} \quad (11)$$

gilt. Die Unterteilung erfolgt anhand der benötigten Leistung des Antriebsstrangs  $P_{ATS}$ , in Abhängigkeit der installierten elektromotorischen Leistung  $P_{EM,max}$ , sowie der Schleppleistung  $P_{Schlepp}$  und der Volllast  $P_{VM,max}$  des VM. Dabei enthält  $P_{ATS}$  anteilig Beiträge vom VM und den verschleißfreien Dauerbremsen (Retarder oder Motorbremse), wie sie von der Gesamtfahrzeugsimulation berechnet werden. Je nachdem in welchem Wertebereich sich  $P_{ATS}$  befindet, wird ein vorherrschender Use Case definiert. In Tabelle 1 sind die Leistungsbereiche und die zugeordneten Fahrzustände nach [8] aufgeführt.

Der Use Case *Rekuperation (1)* deckt den aktiven Bremsbetrieb des Fahrzeugs ab. Während dessen soll möglichst viel der Bremsenergie durch die EM in elektrische Energie umgewandelt werden, um diese im Bordnetz zu nutzen oder in der 48V-Batterie zu speichern.

Tabelle 1: Definition der Use Cases anhand der Antriebsleistung

Bereich der Antriebsleistung	Name des Use Case
$P_{ATS} < P_{Schlepp}$	<i>Rekuperation (1)</i>
$P_{Schlepp} \leq P_{ATS} < 0$ und $P_{ATS} \geq -P_{EM,max}$	<i>Rekuperation mit offener Kupplung (2)</i>
$0 < P_{ATS} \leq P_{EM,max}$	(elektrisch unterstütztes) <i>Segeln (3)</i>
$P_{EM,max} < P_{ATS} < P_{VM,max}$	<i>Teillast (4)</i>
$P_{ATS} = P_{VM,max}$	<i>Volllast (5)</i>

Während der Use Cases *Rekuperation mit offener Kupplung (2)* und *Segeln (3)* wird der VM abgeschaltet, was durch die Versorgung der sicherheitskritischen elektrifizierten Komponenten aus den beiden redundanten Bordnetzen möglich wird. Dabei wird im Use Case (2) das Schleppmoment des VM rekuperiert. Dieser wird abgestellt und die Kupplung geöffnet. Das ist unter der Prämisse, die Längsdynamik des Fahrzeugs nicht zu verändern, nur möglich, wenn die EM das Schleppmoment des VM ersetzt, um damit das Fahrzeug leicht abzubremsen. Beschränkend sind dabei die maximale Leistung des Motors und die Fähigkeit des Systems, die erzeugte elektrische Energie aufzunehmen. Ist eine dieser Voraussetzungen nicht erfüllt, so muss die Kupplung geschlossen und der VM mitgeschleppt werden, wie im konventionellen Betrieb. Für den Fall kleiner positiver Antriebsleistungen kann im Use Case (3) ebenso der Dieselmotor abgestellt werden und das benötigte Vortriebsmoment von der EM gestellt werden. Während sich der Antriebsstrang in *Teillast* befindet, kann die EM motorisch unterstützend betrieben werden, oder generatorisch, um aktiv elektrische Energie zu erzeugen, wenn sie benötigt ist. Dieser konventionell generatorische Betrieb ist während der *Volllast* wegen der bereits beschriebenen Prämisse ausgeschlossen, da ein zusätzliches bremsendes Moment am Antriebsstrang nicht vom VM kompensiert werden kann. Es kann aber der VM durch elektrisches Boosten entlastet werden. Für jeden einzelnen Use Case wird seine Dauer  $\Delta t_i$  und die von der EM umsetzbare mechanische Energie

$$E_{UC_i} = \int_{t_i}^{t_i + \Delta t_i} P_{UC_i} dt \quad (12)$$

hinterlegt, wobei mit  $t_i$  die Startzeit des Use Case bezeichnet ist. In der Leistung  $P_{UC_i}$  ist bereits die maximale EM-Leistung  $P_{EM,max}$  zu jeden Zeitschritt berücksichtigt, sowohl für motorischen

als auch generatorischen Betrieb. Im nächsten Abschnitt wird beschrieben, wie die jeweilige Ausprägung der Use Cases über den gesamten Fahrzyklus geplant und ob und wie stark die EM eingesetzt wird.

#### 4. Bestimmung einer optimalen SOC-Trajektorie

Das Ziel der Optimierung ist die Bestimmung eines SOC-Verlaufs für jede der beiden Batterien, sodass der Kraftstoffverbrauch über den gesamten Fahrzyklus möglichst gering ist, ohne jedoch die Geschwindigkeitstrajektorie des Fahrzeugs zu verändern. Mit der mechanischen Energie  $E_{UC_i}$  im Use Case nach Gleichung (12) wird mit den kennfeldbasierten Wirkungsgraden der elektrischen Maschine  $\eta_{EM}$  und der Batterie  $\eta_{bat48}$  die elektrische Energie  $E_{bat48,i}$  berechnet, die gespeichert bzw. aufgewendet werden soll. Aus dieser ergibt sich eine mögliche Änderung des SOC während der Dauer  $\Delta t_i$  des Use Case zu

$$\Delta SOC_{UC_i} = -\frac{E_{bat48,i}}{Q_{bat48}}, \quad (13)$$

wobei  $Q_{bat48}$  den Gesamtenergieinhalt der 48V-Batterie bezeichnet. Es gilt, dass negative Energien die Batterie laden und zu einer positiven Änderung  $\Delta SOC_{UC_i}$  des Ladezustands führen. Der Beitrag der SOC-Änderung  $\Delta SOC_{Aux,i}$  ergibt sich analog zu Gleichung (13) aus dem Energieverbrauch

$$E_{Aux,i} = \int_{t_i}^{t_i + \Delta t_i} P_{aux48} + P_{DCDC48} dt \quad (14)$$

der Nebenaggregate und dem Energiefluss über den DCDC-Wandler. Zusammen mit der vorhandenen Ladung

$$\Delta SOC_{vorh_i} = x_1 - SOC_{min}, \quad (15)$$

welche abgegeben werden kann und der verfügbaren freien Kapazität in der Batterie

$$\Delta SOC_{frei,i} = SOC_{max} - x_1, \quad (16)$$

um weitere Ladung zu speichern, kann der minimale SOC-Hub

$$\Delta SOC_{min,i} = \begin{cases} \Delta SOC_{Aux,i}, & \text{für } UC_i \in \{1,2\} \\ \max\{(\Delta SOC_{UC_i} + \Delta SOC_{Aux,i}), \Delta SOC_{vorh,i}\}, & \text{für } UC_i \in \{3,4,5\} \end{cases} \quad (17)$$

und der maximale SOC-Hub

$$\Delta SOC_{max,i} = \begin{cases} \min\{(\Delta SOC_{UC_i} + \Delta SOC_{Aux,i}), \Delta SOC_{frei,i}\}, & \text{für } UC_i \in \{1,2\} \\ \Delta SOC_{frei,i}, & \text{für } UC_i \in \{3,4\} \\ \min\{\max\{\Delta SOC_{Aux,i}, 0\}, \Delta SOC_{frei,i}\}, & \text{für } UC_i \in \{5\} \end{cases} \quad (18)$$

in Abhängigkeit des momentanen Use Case bestimmt werden. Die Werte von  $UC_i$  beziehen sich dabei auf die Nummerierung der Use Cases in Tabelle 1. Durch die Beschränkung der

erreichbaren SOC-Änderung nach Gleichung (17) und (18) werden die vorausliegenden Streckeninformationen der einzelnen Use Cases im Optimierungsalgorithmus berücksichtigt und es wird sichergestellt, dass nur zulässige Energiemengen umgesetzt werden.

Die Optimierungsvariablen sind der SOC-Hub  $u_1$  und der Skalierungsfaktor der DCDC-Wandler-Leistung  $u_2$ . Das resultierende Optimalsteuerungsproblem

$$\min_u \left\{ \Phi_{\text{term}}(x[N]) + \sum_{k=1}^{N_{\text{UC}}-1} \left( \int_{t_k}^{t_k + \Delta t_k} \dot{m}_{\text{fuel}}(\omega, M(u_1)) dt + J_{\text{recup},k} \right) \right\} \quad (19)$$

$$\text{u.B.v.} \quad x_1[k+1] = x_1[k] + u_1[k] \quad (20)$$

$$x_2[k+1] = x_2[k] + \frac{E_{\text{bat24}}(u_2[k])}{Q_{\text{bat24}}} \quad (21)$$

$$x_1[0] = x_{10} \quad \text{und} \quad x_2[0] = x_{20} \quad (22)$$

$$\Delta \text{SOC}_{\min, i} \leq u_1[k] \leq \Delta \text{SOC}_{\max, i} \quad (23)$$

$$-1 \leq u_2[k] \leq 1 \quad \forall k \in \{1, \dots, (N_{\text{UC}} - 1)\} \quad (24)$$

wird mit der Dynamischen Programmierung gelöst, die im Zusammenhang mit hybriden Antriebssträngen häufig eingesetzt wird (vgl. [5] - [8]). Die Terminierungskosten

$$\Phi_{\text{term}}(x[N]) = K_{\text{SOC48}}|x_{1,\text{end}} - x_1[N]| + K_{\text{SOC24}} \quad (25)$$

bestehen zum einen aus der Abweichung des Ladezustands der 48V-Batterie am Ende des Fahrzyklus  $x_1[N]$  vom gewünschten Endzustand  $x_{1,\text{end}}$ . Der Faktor  $K_{\text{SOC48}} > 0$  ist dabei so zu wählen, dass über den Fahrzyklus eine ausgeglichene Ladebilanz der Batterie sichergestellt ist. Zum anderen geht der Wert von  $x_2$  zum Zeitpunkt  $N$  über den Term

$$K_{\text{SOC24}} = \begin{cases} J_{\text{inf}} & \text{für } x_2[N] < x_{2,\text{end}} \\ 0 & \text{sonst} \end{cases} \quad (26)$$

ein, der jede Unterschreitung des geforderten Ladezustands  $x_{2,\text{end}}$  mit Kosten von  $J_{\text{inf}}$  bestraft, wobei  $J_{\text{inf}}$  größer sein muss, als alle sonst auftretenden zulässigen Kosten. Im Fall einer Rekuperation bietet das Fahrzeug mit 48V-Bordnetz keinen Vorteil bezüglich Kraftstoffeinsparung gegenüber einem konventionellen Fahrzeug. Dementsprechend muss ein weiterer Beitrag

$$J_{\text{recup},k} = K_{\text{recup}}(\Delta \text{SOC}_{\max, k} - x_1) \quad (27)$$

in der Kostenfunktion sicherstellen, dass keine Rekuperationsphase verpasst oder nur unzureichend genutzt wird. Nicht rekuperierte Energie wird mit zusätzlichen Kosten bestraft und mit dem Faktor  $K_{\text{recup}} > 0$  gewichtet.

## 5. Reaktive Basisbetriebsstrategie

Um die optimale Betriebsstrategie (OBS) zu bewerten, wird diese mit einer reaktiven Basisbetriebsstrategie (BBS) verglichen. Für die BBS wird angenommen, dass die vorausschauende Regelung des Antriebsstrangs nach dem Stand der Technik potenzielle Segelphasen prädizieren kann. Diese kann das reaktive 48V-Bordnetz nutzen, wenn die aktuellen Werten der Ladezustände es zulassen. Es kann also nur anhand von Schwellwerten entschieden werden, welches Moment die EM stellen oder welche Leistung über den DCDC-Wandler fließen soll. Ein Schwellwert des Ladezustands der 48V-Batterie unterdrückt bei zu niedrigem SOC den Segelbetrieb. Eine weitere Schranke begrenzt die Möglichkeit zu boosten. Unterhalb dieses Wertes wird nur das Bordnetz versorgt, um nicht mit dem Generator im befeuerten Zustand des VM elektrische Energie erzeugen zu müssen. Erst, wenn durch Rekuperation wieder genügend Energie im System gespeichert ist, werden alle Funktionen wieder freigegeben. Rekuperierte Energie wird so schnell wie möglich wieder ausgegeben, um zu vermeiden, dass wegen einer vollen Batterie in einer folgenden Rekuperationsphase Bremsenergie nicht zurückgewonnen werden kann. Nur der OBS ist es möglich, die Zustände des Bordnetzes zu prädizieren, um Rekuperations- und Segelphasen maximal auszunutzen zu können. Das unterschiedliche Verhalten der Strategien wird im nächsten Abschnitt verglichen.

## 6. Auswertung und Vergleich der optimalen Betriebsstrategie

Als Fahrzyklus für die Simulationen, welche mit einem Gesamtgewicht von 34,6 Tonnen durchgeführt sind, dient die Strecke von Wörth am Rhein nach Verdun in Frankreich und zurück mit einer Fahrtzeit von etwa 7 Stunden und 20 Minuten. Der Vergleich der Simulationsergebnisse beider Strategien ergibt einen relativen Verbrauchsvorteil der OBS von 0,4 % gegenüber der BBS. Nachfolgend werden die Effekte beschrieben, die zu dieser Kraftstoffeinsparung führen. In Bild 3 sind die zeitlichen SOC-Verläufe der 48V-Batterien dargestellt. Es ist zu beachten, dass die SOC-Bilanz für die reaktive Strategie nicht ausgeglichen ist und der Ladezustand am Ende des Zyklus unterhalb seines Startwertes liegt. Diese geringe Differenz enthält einen weiteren kleinen Beitrag zum Verbrauchsvorteil der optimalen Strategie, der im oben genannten Prozentwert nicht wiedergegeben ist. Es ist zu erkennen, dass das allgemeine Level des SOC im Fall der OBS höher liegt, da durch die Kenntnis der vorausliegenden Strecke die Energie aufgespart und zu möglichst günstigen Zeitpunkten eingesetzt werden kann, ohne Gefahr zu laufen, wegen einer zu vollen Batterie Rekuperationspotential nicht nutzen zu können. Besonders der erste Streckenabschnitt (bis ca. 4000 Sekunden) zeigt, wie hier kaum Batterieenergie eingesetzt wird, um nicht in Bereiche eines generatorischen Betriebs zu kommen. Kurz bevor bei etwa 5000 Sekunden viel Rekuperationsenergie zur Verfügung steht,

sinkt der SOC bis zu seinem zulässigen Minimum. Weiterhin wird in diesem Streckenabschnitt die anfängliche vorhandene Ladung der 24V-Batterie genutzt, um das 48V-Netz zu entlasten. Dies ist in Bild 4 zu erkennen, welches die Verläufe der 24V-Batterien darstellt. Die BBS fordert für das Laden der 24V-Starterbatterie zu Beginn des Zyklus maximale Leistung vom DCDC-Wandler, um die Batterie vollzuladen.

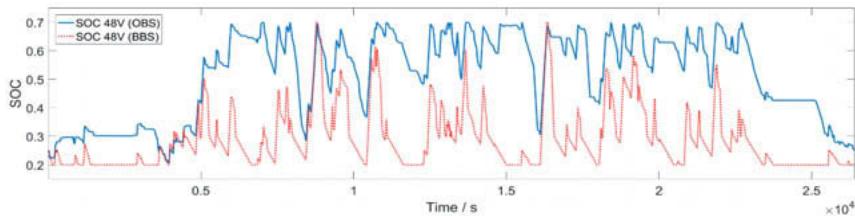


Bild 3: SOC-Verlauf der 48V-Batterien für beide Strategien

Dadurch wird auch bei kürzeren Fahrten die Startfähigkeit des Fahrzeugs sichergestellt. Dagegen kann die OBS durch Vorausschau die gespeicherte Energie in der Batterie ausnutzen, um generatorischen Betrieb zu vermeiden. Durch die Randbedingung  $x_{2,end}$  der OBS zum Ende des Zyklus ist dennoch das Erreichen des maximalen Ladezustands gewährleistet. Bild 5 zeigt einen Ausschnitt des Fahrzyklus, in dem alle verschiedenen Use Cases auftreten und das unterschiedliche Verhalten der Strategien deutlich wird. Nach dem Teillastbetrieb zu Beginn ist die OBS in der Lage die Segelphase bei Use Case (3) elektrisch zu stellen und dabei den VM abzustellen. Die BBS muss ein leicht negatives Moment stellen, um die untere SOC-Schwelle nicht zu unterschreiten. Während der *Vollastphase* entlastet die OBS den VM, da hier der größte Verbrauchsvorteil in Bezug auf die aufgewendete elektrische Energie erreicht wird. Außerdem ist bekannt, dass der eingesetzte SOC in der bald folgenden Brems- und Rollphase wieder rekuperiert werden kann. Etwa ab dem Zeitpunkt 16.000 s beginnt diese Phase, welche von der OBS bis zur nächsten *Teillast* ausgenutzt wird, um konstant mit möglichst geringem Strom die Batterie zu laden. Dies erklärt sich aus dem Innenwiderstand der Batterie im Modell nach Gleichung (3), wodurch bei großen Strömen mehr Leistung am Widerstand verloren geht. Diese *Teillastphase* nutzt die BBS, um den sehr hohen SOC zu reduzieren und boostet diese Energie zurück auf den Antriebsstrang. Jedoch ist, wie erwähnt, ein Einsatz während der *Vollast* profitabler. Die Steuerung des Energieflusses über den DCDC-Wandler wird beispielhaft anhand der Bild 6 und Bild 7 dargestellt.

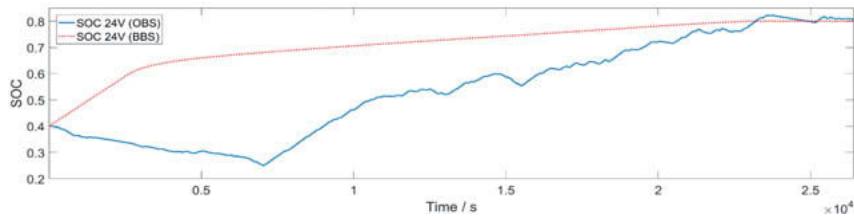


Bild 4: SOC-Verlauf der 24V-Batterien für beide Strategien

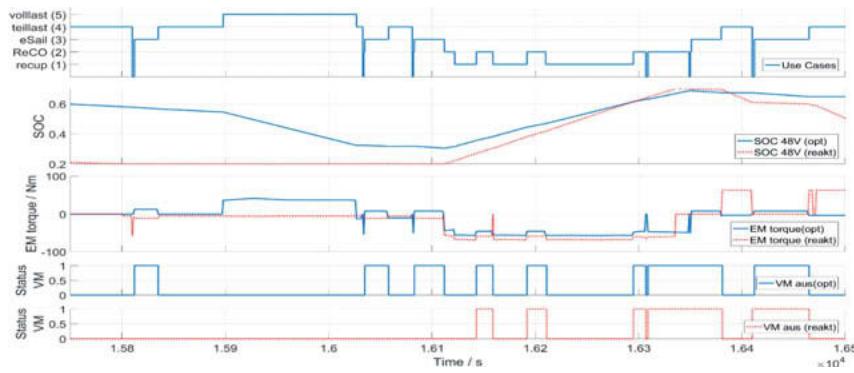


Bild 5: Anwendungsfälle aller Use Cases

Der SOC der 48V-Batterie ist in Bild 6 besonders zu Beginn der Situation hoch und wird vor der Rekuperationsphase zwischen 7400 und 7500 Sekunden reduziert, indem durch häufiges Stellen von  $r_{DCDC} = 1$  Energie in das 24V-Bordnetz transferiert wird. Dies ist demnach energetisch sinnvoller, als während des Use Case *Teillast* mit geringem Einfluss auf den globalen Kraftstoffverbrauch zu boosten. Im Gegensatz dazu wird in Bild 7 der Ladezustand der 24V-Batterie reduziert, indem diese nicht geladen wird ( $r_{DCDC}$  häufig klein), um die geringe Energie in der 48V-Batterie zur Substitution von VM-Moment während der *Vollast* zu nutzen, ohne die untere SOC-Grenze für das 48V-System zu verletzen. Diese Steuerungen sind nur durch Kenntnis der vorausliegenden Leistungsverläufe bestimmbar und können daher von der BBS so nicht geplant und gestellt werden.

## 7. Zusammenfassung und Ausblick

In diesem Beitrag wurde eine optimale Betriebsstrategie für ein 48V-Bordnetz im schweren Nutzfahrzeug hergeleitet. Die Planung des SOC-Verlaufes und des Energieflusses zwischen

den beiden Spannungslagen im Bordnetz durch einen Optimierungsalgorithmus basiert auf der heuristischen Unterteilung der Strecke in Phasen unterschiedlicher Leistungsbedarfe. Der Vergleich mit einer reaktiven Basisstrategie zeigt, dass durch effizienten Einsatz der rekuperierten Energie in Antriebsstrang und Bordnetz eine erkennbare Kraftstoffeinsparung erreicht werden kann. Weiterführend bieten Nebenverbraucher mit relativ hohem Leistungsbedarf und eigenem Energiespeicher, wie Luftpumpe oder Klimakompressor, durch eine Elektrifizierung und vorausschauende Planung ihres Einsatzes weiteres Kraftstoffeinsparungspotential. Diese können in das vorgestellte Verfahren integriert werden, wie auch eine prädiktive Strategie zur Vermeidung von Abregelungen der elektrischen Komponenten durch Temperaturgrenzen.

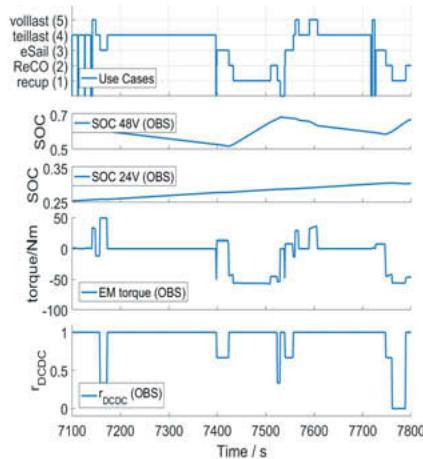


Bild 6: Entladen der 48V-Batterie über den DCDC-Wandler

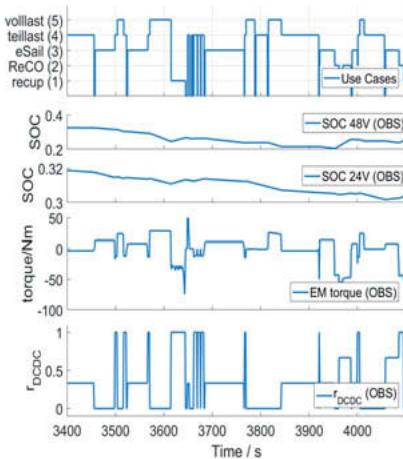


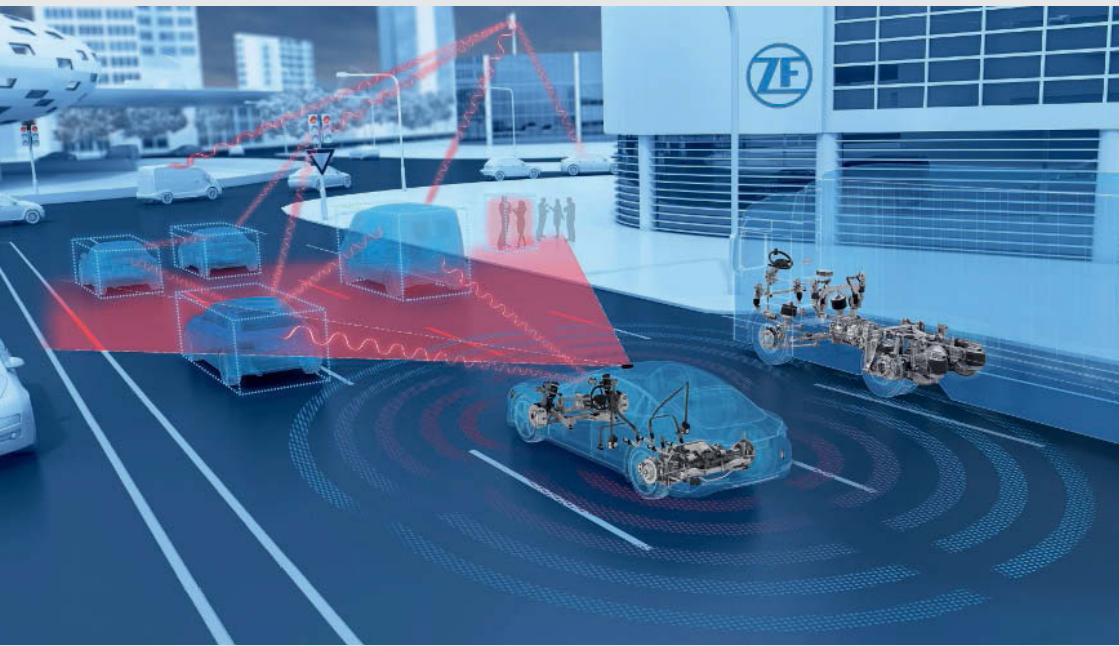
Bild 7: Entlastung der 48V-Batterie, um zu boosten

## Literatur

- [1] Karbowski, D.; Delorme, A.; Rousseau, A.: Modeling the Hybridization of a Class 8 Line-Haul Truck. SAE Commercial Vehicle Engineering, 2010
- [2] Zirn, O.; Krauth, S.; Ahlborn, M.: Hybridisation Potentials for Heavy Trucks Considering Route Topography. 7th Journal of Mechanics Engineering and Automation, 2016
- [3] Timmann, M.; Renz, M.: 48V at Mercedes-Benz – options for further applications. 14. Internationales Stuttgarter Symposium (Proceedings) 2014, S. 645–663
- [4] Hendricks, T.; O'Keefe, M.: Heavy Vehicle Auxiliary Load Electrification for the Essential Power System Program: Benefits, Tradeoffs, and Remaining Challenges. SAE Technical Paper, 2002-01-3135, 2002
- [5] Sonntag, M.; Kauffmann, F.; Gehring, O.; Sawodny, O.: Vorausschauendes HV-Batteriemanagement für E-Hybrid-LKW im Fernverkehr. 6. VDI/VDE-Fachtagung AUTOREG Steuerung und Regelung von Fahrzeugen und Motoren, 2013
- [6] Terwen, S.; Back, M.; Krebs, V.: Predictive Powertrain Control for Heavy Duty Trucks. IFAC Symposium on Advances in Automotive Control, 2004, S. 105–110
- [7] Onori, S.; Serrao, L.; Rizzoni, G.: Hybrid Electric Vehicles. Energy Management Strategies. London: Springer 2016
- [8] Heppeler, G.; Sonntag, M.; Sawodny, O.: Predictive planning of the battery state of charge trajectory for hybrid-electric passenger cars. 15. Internationales Stuttgarter Symposium, 2015







ISBN 978-3-18-092349-9

Bildquelle: © ZF Friedrichshafen AG