

## 30. VDI-Fachtagung

# Technische Zuverlässigkeit 2021

Entwicklung und Betrieb zuverlässiger Produkte

27. und 28. April 2021, Online-Tagung

Bildquelle: © T. Frohn





**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 2021**

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 Manuskriptdruck.

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 978-3-18-092377-2

# Inhalt

Vorwort . . . . .1  
P. Zeiler, Hochschule Esslingen, University of Applied Sciences Göppingen

► **Prognostics and Health Management (PHM) und Industrie 4.0**

---

Restlebensdauervorhersage für Filtrationssysteme mittels Random Forest . . . . . 3  
D. Riegel, Robert Bosch GmbH, Reutlingen;  
H. Hitzer, Bosch-Rexroth AG, Horb am Neckar

Untersuchung von Datensätzen und Definition praxisrelevanter Standardfälle im Kontext  
von Predictive Maintenance. . . . .17  
F. Mauthe, M. Hönig, P. Zeiler, Fakultät Mechatronik und Elektrotechnik/Maschinen und  
Systeme, Hochschule Esslingen, Göppingen

Methodik zur Schadensquantifizierung in hydraulischen Axialkolbeneinheiten unter  
variablen Betriebsbedingungen . . . . .33  
H. Hitzer, Bosch-Rexroth AG, Horb am Neckar;  
D. Hast, Bosch-Rexroth AG, Schwieberdingen;  
S. Böttinger, Universität Hohenheim, Stuttgart

► **Beschleunigte Erprobung, Teststrategien und Zuverlässigkeitsvalidierung**

---

Innovative Konzepte zur Zuverlässigkeitsbetrachtung von Hardware- und  
Software-Komponenten von Beatmungsgeräten – Entwicklungsbegleitende  
Maßnahmen zur Zuverlässigkeitsabsicherung einer neuen Ventilator-Generation . . . . . 49  
M. Meyer, Drägerwerk AG & Co. KGaA, Lübeck;  
J. Nuffer, T. Pfeiffer, M. Rauschenbach, J. Holz, Gruppe Zuverlässigkeit und Sicherheit aktiver  
Systeme, Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF,  
Darmstadt

Simulation und Analyse mechanischer Bremsenschocks an Elektromotoren . . . . .63  
D. Schepers, L. Bodenröder, Hochschule Ruhr West, Mülheim/Ruhr;  
J. Börcsök, Universität Kassel, Kassel;  
F. Rieger, SEW-EURODRIVE GmbH & Co. KG, Bruchsal

**Effiziente Zuverlässigkeitsabsicherung durch Berücksichtigung von Simulations-  
ergebnissen am Beispiel einer Hochvolt-Batterie. . . . . 75**

A. Grundler, M. Dazer, B. Bertsche, Institut für Maschinenelemente, Universität Stuttgart;  
M. Göldenboth, F. Stoffers, Mercedes-Benz AG, Sindelfingen

**Effizienzsteigerung in der Erprobung durch das strategische Validieren von Annahmen. . . . . 89**

J.-F. Mischko, S. Einbock, Robert Bosch GmbH, Schwieberdingen;  
R. Wagener, Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF,  
Darmstadt

► **Management von Zuverlässigkeit und Sicherheit**

---

**Safety-Management für mechatronische Systeme: Ein elementarer Baustein in der  
Produktentwicklung am Beispiel der Marinetechnik . . . . . 103**

J. Isermann, H. Neuhaus, C. Blank, E. Yücel, ATLAS ELEKTRONIK GmbH, Bremen

**Zuverlässigkeitsmanagement und Haftungsfragen – ein Betrag zur Existenzsicherung im  
Unternehmen . . . . . 119**

A. Braasch, Institut für Qualitäts- und Zuverlässigkeitsmanagement GmbH, Wuppertal und  
Hochschule Ruhr West, Mülheim a.d. Ruhr;  
H. Wüsteney, Allianz Risk Consulting Liability, München;  
F. Plinke, Institut für Qualitäts- und Zuverlässigkeitsmanagement GmbH, Hamburg

**Zuverlässigkeitsnachweis entlang des Produktentwicklungsprozesses –  
Herausforderungen in der praktischen Umsetzung. . . . . 121**

T. Leopold, Hochschule Esslingen

► **Modellierung und Simulation von Zuverlässigkeit und Verfügbarkeit**

---

**Bestimmung der Systemzuverlässigkeit unter Berücksichtigung der Systemstruktur und  
Einbindung von Vorwissen. . . . . 133**

S. Lämmle, P. Kupfer, ZF Friedrichshafen AG, Friedrichshafen;  
S. Feth, J. Fiedler, Fraunhofer-Institut für Techno- und Wirtschaftsmathematik, Kaiserslautern

**Empirische Lebensdauerprädiktion von Elektrolytkondensatoren in hochbeanspruchten  
Applikationen elektrifizierter Fahrzeuge . . . . . 147**

P. Adler, Volkswagen Group Components, Salzgitter

**Messung des Alterungszustand von LEDs im verbauten Zustand über ihre elektrischen Größen und die Vorhersage der Zuverlässigkeit . . . . . 159**  
B. Weigt, K. Homeyer, Industrieelektronik und Lichttechnik, Hochschule Hannover;  
R. Lachmayer, Fakultät für Maschinenbau, Institut für Produktentwicklung und Gerätebau, Leibniz Universität Hannover

**Wie Alterungsmodelle für integrierte Transistoren die Entwicklung zuverlässiger Systeme unterstützen . . . . . 173**  
A. Lange, K.-U. Giering, R. Jancke, Fraunhofer-Institut für Integrierte Schaltungen IIS, Institutsteil Entwicklung Adaptiver Systeme EAS, Dresden

► **Entwicklung und Absicherung zuverlässiger Komponenten und Systeme**

---

**Entwicklungsbegleitende domänenübergreifende Zuverlässigkeitsanalyse von Einzelkomponenten bis hin zum Gesamtsystem am Beispiel einer Lithium-Ionen-Batterie zelle . . . . . 185**  
S. Kupjetz, T. Pfeiffer, J. Holz, Fraunhofer Institute for Structural Durability and System Reliability LBF, Darmstadt

**Zuverlässigkeitsanalyse von PV-Anlagen und Wechselrichtern. . . . . 197**  
A. Benz, K. Hintz, M. Diesch, M. Dazer, B. Bertsche, Institut für Maschinenelemente, Universität Stuttgart;  
J. Knoch, Electronicon Kondensator GmbH, Gera;  
D. Clemens, SMA Solar Technology AG, Niestetal

**Konzeption und Vergleich einer Methode zur Berechnung der Zuverlässigkeit bei variabler Belastung auf Basis einer probabilistischen Schädigungsakkumulation . . . . . 213**  
P. Zeiler, Fakultät Maschinen und Systeme, Hochschule Esslingen, Göppingen

► **Künstliche Intelligenz, Maschinelles Lernen und Big-Data-Analysen**

---

**Nutzung von Neuronalen Netzen zur Effizienzsteigerung in der optimalen Zuverlässigkeitstestplanung . . . . . 227**  
P. Mell, T. Herzig, B. Bertsche, Institut für Maschinenelemente, Universität Stuttgart

**Erstellung eines digitalen Zwillings für die additive Fertigung mittels KI – Problemanalyse der additiven Fertigung zur Vermeidung von Druckfehlern. . . . . 239**  
S. Wenzel, E. Slomski-Vetter, T. Melz, Fachgebiet Systemzuverlässigkeit, Adatronik und Maschinenakustik SAM, Technische Universität Darmstadt

## ► Erfassung und Auswertung von Nutzungs- und Ausfalldaten

---

<b>Ableitung von Grenzwerten für die Tauschaufbereitung auf Basis von Zuverlässigkeitsanalysen . . . . .</b>	<b>255</b>
--	------------

A. Kroner, Mercedes-Benz AG, Stuttgart;  
B. Bertsche, Institut für Maschinenelemente, Universität Stuttgart

<b>Verfahren zur Prognose von Garantiekosten und Instandhaltungsaufwand. . . . .</b>	<b>271</b>
--	------------

T. Renz, H. Jung, IZP Dresden mbH, Dresden

## ► Aspekte autonomer Systeme

---

<b>Berücksichtigung menschlicher Zuverlässigkeit in der Gestaltung autonomer Systeme . . . .</b>	<b>281</b>
--	------------

O. Sträter, Arbeits- und Organisationspsychologie, Fachbereich Maschinenbau,  
Universität Kassel

<b>Ein Ansatz zur Wiederherstellung ausgefallener Hardwarekomponenten in Fail-Operational Architekturen – Eine Erweiterung von FDIRO . . . . .</b>	<b>297</b>
--	------------

T. Kain, A. Mehlhorn, Volkswagen AG, Wolfsburg;  
T. Horeis, IQZ GmbH, Hamburg;  
J. Heinrich, IQZ GmbH, Wuppertal;  
H. Tompits, Technische Universität Wien, Österreich

<b>Ansatz zur methodischen Analyse und Absicherung des Funktionalkonzepts voll automatisierter Kraftfahrzeuge . . . . .</b>	<b>309</b>
---	------------

M. Rauschenbach, S. Kupjetz, Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF, Darmstadt;  
C. Wolschke, T. Braun, Fraunhofer-Institut für Experimentelles Software Engineering IESE, Kaiserslautern



# BEST MATCH for BEST TALENTS

INGENIEUR.de  
BEST MATCH

powered by  SCOTT

## So findet Sie Ihr Traumjob!

Ingenieure aller Fachrichtungen, Absolventen und wechselwillige Professionals aufgepasst:  
Sagen Sie uns, was Sie können, wollen und lieben – dann bieten Ihnen die besten  
Unternehmen den passenden Job für Ihr Talent. Schnell, unkompliziert, ohne Aufwand.

### DAS SIND IHRE VORTEILE:

Einfache Profilerstellung | Persönliche Beratung | Passgenaue Job-Angebote |  
Keine aufwändige Job-Suche | Unternehmen bewerben sich bei Ihnen | Kostenfreie Nutzung |  
**Transparenz:** alle wichtigen Informationen zum Traumjob |  
**Sicher:** Ihr Arbeitgeber hat keine Einsicht in Ihr Profil

**JETZT ALS TALENT REGISTRIEREN:**  
**BESTMATCH.INGENIEUR.DE**





## Vorwort

Sehr geehrte Damen und Herren,

durch die zunehmende Digitalisierung und Vernetzung, beispielsweise in einer Smart Factory im Kontext von Industrie 4.0, werden hohe Anforderungen an die Zuverlässigkeit, die Verfügbarkeit und die Sicherheit von Maschinen und Anlagen gestellt. Dies erfordert den konsequenten Einsatz und die ständige Weiterentwicklung von Methoden und Modellen der Zuverlässigkeitstechnik entlang des gesamten Lebenszyklus zur Planung, Entwicklung und Absicherung der Zuverlässigkeit.

Die zunehmende Digitalisierung bietet durch die steigende Zugänglichkeit und Verfügbarkeit von relevanten Daten gleichzeitig enorme Chancen und neue Möglichkeiten für die Anwendung dieser Methoden und Modelle für Zuverlässigkeitsanalysen und -prognosen.

Der vorliegende Tagungsband enthält die Manuskripte der Referenten, soweit sie zum Zeitpunkt der Drucklegung vorlagen. Der Tagungsleiter und die Mitglieder des Programmausschusses danken allen, die beim Gelingen der Veranstaltung mitgewirkt haben.

Die VDI Wissensforum GmbH und die VDI-Gesellschaft Produkt- und Prozessgestaltung (GPP) führen die Tagung **Technische Zuverlässigkeit (TTZ)** zum 30. Mal durch.

Wir freuen uns, Sie trotz der derzeitigen Covid-19 Pandemie zur Online-Tagung „Technische Zuverlässigkeit“ in Form von „Live-Vorträgen“ am **27. und 28. April 2021** begrüßen zu dürfen.

Wir hoffen auf Ihr Verständnis in dieser außergewöhnlichen Lage und wünschen Ihnen beste Gesundheit!

Im Namen des Programmausschusses

Tagungsleiter

**Prof. Dr.-Ing. Peter Zeiler**

Leiter des Forschungsbereichs Zuverlässigkeitstechnik und Prognostics and Health Management  
Fakultät Maschinen und Systeme  
Hochschule Esslingen – University of Applied Sciences Göppingen



# Restlebensdauervorhersage für Filtrationssysteme mittels Random Forest

M.Sc. **Daniel Riegel**, Robert Bosch GmbH, Reutlingen;  
M.Sc. **Hannes Hitzer**, Bosch Rexroth AG, Horb am Neckar

## Kurzfassung

Dieser Beitrag beschreibt ein Verfahren zur datengetriebenen Restlebensdauervorhersage für Filtrationssysteme auf Grundlage von Random-Forest Modellen. Die Besonderheit beruht auf einem speziellen Merkmalsextraktionsprozess, der unabhängig von physikalischen Zusammenhängen anwendbar ist. Weiter zeigt sich das Verfahren als besonders vorteilhaft, wenn verrauschte Signale vorliegen. Anhand eines Messdatensatzes mit 48 Beispieldaten wird die Vorhersagegenauigkeit und Generalisierungsfähigkeit getestet und einem einfachen linearen Modell gegenübergestellt. Die Ergebnisse zeigen auch den Einfluss auf die Vorhersagegenauigkeit in Abhängigkeit des Umfangs der zur Verfügung stehenden Trainingsdatensätze.

## 1. Einleitung

Filtrationsprozesse spielen eine Schlüsselrolle in vielen industriellen Bereichen. Ein anspruchsvolles Beispiel ist die Abscheidung von Partikeln aus Kraftstoffen. Aus wirtschaftlichen, aber auch umwelttechnischen Gründen bestehen stetige Bestrebungen, Einspritzsysteme im Hinblick auf die Effizienz des Verbrennungsvorgangs zu steigern und die Emission von Schadstoffen zu minimieren. Ein Begleiteffekt, der mit den Maßnahmen zur Optimierung einhergeht, ist die gesteigerte Anfälligkeit gegenüber Verunreinigungen im Medium. Systemhersteller und Betreiber sind daher gezwungen die Reinheit des Kraftstoffes bei Eintritt in das Einspritzsystem zu gewährleisten [1]. Ein generelles Problem beim Filtrationsprozess ist jedoch die zunehmende Ablagerung von Partikeln im Filter. Ab einem bestimmten Maß an Verstopfung wird der Durchlauf des Mediums unterbrochen und der Differenzdruck steigt. Wartung und regelmäßige Reinigung des Filtersystems sind daher eine Grundvoraussetzung für die Aufrechterhaltung des Betriebszustandes [2].

Auch aus Sicherheitsaspekten ist die Filtration von Flüssigkeiten relevant. So kann beispielsweise beim Betrieb eines Luftfahrzeugs der Ausfall einer Treibstoffzuleitung oder der Hydraulik des Fahrwerks zu einem katastrophalen Ereignis führen. Dazu zeigt [3] in seinem Bericht die Hauptursachen für Filterverstopfung und Wartungskonzepte für verschiedene Flugzeugtypen von Boeing. Hauptursachen sind Rost und Verschmutzungen verschiedenster Art, welche

während der Lagerung in Tanks in den Treibstoff gelangen. Das spezifizierte Wartungsintervall des Treibstofffilters einer Boeing 747-400 beträgt 7500 Flugstunden. Dennoch wechseln viele Airlines den Filter bereits wesentlich früher schon nach 2000 Flugstunden, um Startabbrüche und ungeplante/Not-Landungen aufgrund von Filterverstopfungen zu vermeiden [3]. Ein Nachteil dieser präventiven Wartungskonzepte ist, dass die meisten Filter lange vor Ihrer eigentlichen Verstopfung gewechselt werden, und ein im obigen Beispiel dreimal höherer Wartungsaufwand entsteht als bei reaktiver Wartung. Jene präventiven und reaktiven Wartungskonzepte sind jedoch vermeidbar, wenn durch Modellbildung die Restlebensdauer der Filter individuell und während des Betriebs vorhergesagt werden kann. Eine derartige Vorgehensweise wird allgemein auch als vorausschauende Instandhaltung bezeichnet und kann Anwendung im Prognostics and Health Management (PHM) finden.

Für den Anwendungsfall von Filtrationssystemen beschäftigen sich [2] mit physikalischen Modellen zur Beurteilung verstopfter Filter und erarbeiten einen Ansatz auf Basis der Ergun Gleichung [4] zur Restlebensdauervorhersage. Eingangssignale sind dabei der Druckverlust über dem Filter, die Durchflussrate des Mediums, ein Indikator über die Partikelgrößenverteilung im Medium sowie das Fest-Flüssigverhältnis im Medium. Ein wesentlicher Nachteil des physikbasierten Ansatzes ist jedoch die aufwändige Bestimmung von Parametern, wie z.B. die Detektion der Filterkuchenhöhe mittels Bildverarbeitungstechnologie. Um die erwähnten Nachteile zu umgehen und um Potenzial für weitere Anwendungsgebiete aufzuzeigen, stellt dieser Beitrag eine generische, datengetriebene Methodik vor. Diese stützt sich auf die Verwendung von Random Forest Regressionsmodellen und ermittelt die zu erwartende Restlebensdauer ohne Kenntnis physikalischer Zusammenhänge im Modell.

## 2. Random Forest (theoretischer Hintergrund)

Random Forest stellt ein Modell-Ensemble (im übertragenen Sinn einen Wald) von Entscheidungsbäumen dar, welches zur Klassifikation oder Regression verwendet wird. Die Motivation für den Einsatz eines Modell-Ensembles und gleichbedeutender Vorteil ist die Steigerung der Genauigkeit gegenüber Einzelmodellen. Analog zur Befragung von Experten, beruht die vorteilhafte Eigenschaft auf der Tatsache, dass die Summe an relativ unkorrelierten Einzelmodellen eine bessere Aussage liefert als ein einzelnes Modell [5, 6]. Im Fall einer Klassifikationsaufgabe stimmt jeder Entscheidungsbaum für eine Klasse, wobei die endgültige Entscheidung dem Modalwert der Entscheidungen aller Bäume entspricht. Für die Regressionsproblematik ist der vorhergesagte Wert gleich dem arithmetischen Mittelwert aller Vorhersagewerte. In der Erstellung des Modells, dem sogenannten Trainingsprozess, stützt sich die Methodik auf Bagging [7]. Bagging ist ein Kofferwort für Bootstrap Aggregating, und wird im Folgenden (siehe

auch Bild 1) weiter erläutert. Methodisch werden beim Bootstrapping aus einem Trainingsdatensatz  $D$  des Umfangs  $n$  eine Anzahl  $m$  Stichproben  $D_i$  mit Umfang  $n'$  mit Zurücklegen gezogen. Für  $n = n'$  und  $n \rightarrow \infty$  sind  $1 - 1/e$ , also ungefähr 63 % der gezogenen Proben in  $D_i$  als unterschiedlich zu erwarten, während der Rest Duplikaten aus  $D$  entspricht [8].

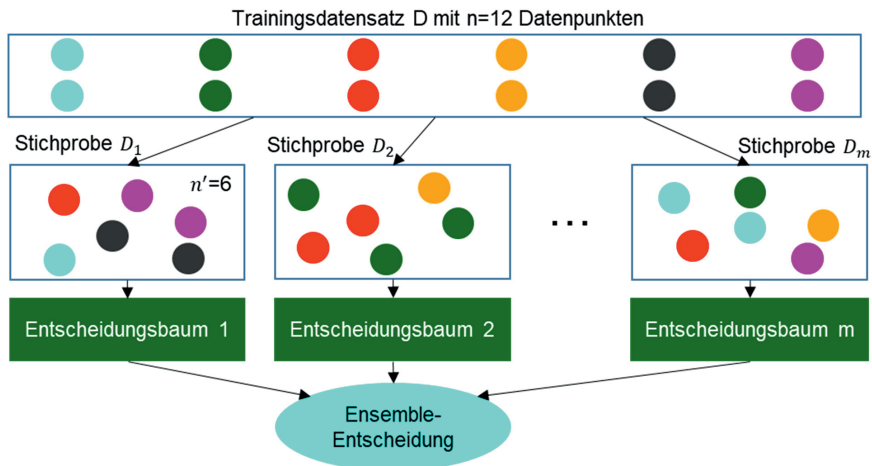


Bild 1: Funktionsweise von Bootstrapping und Aggregating von Random Forest Modellen

Anschließend wird aus dem durch Bootstrapping gezogenen Datensatz eine zufällige Untermenge an Merkmalen ausgewählt und ein Entscheidungsknoten erstellt. Die Anzahl an Merkmalen in dieser Untermenge ist limitiert und muss durch eine Hyperparameter-Optimierung bestimmt werden. Diese Untermenge stellt dabei sicher, dass ein Entscheidungsbaum nicht bestimmte, einzelne Merkmale auswählt, sondern alle gleichermaßen berücksichtigt. Innerhalb dieser Untermenge wird die Auswahl des Merkmals für einen Knoten bei Regressionsproblemen durch die Reduktion der Varianz (hier mittlerer quadratischer Fehler wie in Formel 1) ermittelt [9].

$$MSE = \frac{1}{n'} \sum_{i=1}^{n'} (y_i - \mu)^2 \quad (1)$$

Dabei stellt  $y_i$  den wahren Wert (Label) eines Datenpunktes der Bootstrapping-Stichprobe und  $\mu$  den Mittelwert über alle Stichproben dar. Der Algorithmus startet mit seiner Auswahl an der Wurzel, welche der Bootstrapping-Stichprobe entspricht [10]. Von der Wurzel aus werden weitere Knoten ermittelt, wobei sich die Wurzel und jeder Knoten immer in genau zwei Äste aufteilen. Knoten, an denen keine Teilung mehr stattfindet, werden als Blätter bezeichnet und

stellen die diskreten Vorhersagewerte dar. Der Algorithmus arbeitet üblicherweise nach dem Top-Down-Ansatz [11]. Da jeder Baum einzeln und unabhängig trainiert wird, besteht die Möglichkeit einer effizienten Parallelisierung und somit einer Verkürzung der Trainingszeit [12]. Durch das Bootstrapping der Stichproben, sowie der limitierten Anzahl an Merkmalen, die in jedem Knoten berücksichtigt werden, entsteht bei der Aggregation der einzelnen Bäume (Aggregating) und Mittelung der Vorhersagewerte eine Robustheit gegenüber Ausreißern und stochastischem Rauschen. Weitere vorteilhafte Eigenschaften dieser Vorgehensweise sind die Verarbeitung hochdimensionaler Variablen sowie die effiziente Nutzung für laufzeitkritische Anwendungen (Parallelisierungsmöglichkeit).

### 3. Datensatz Filterverschmutzung

Als Grundlage für die Demonstration der Anwendung von Random Forest Modellen wird der Datensatz der Prognostics and Health Management Europe Conference 2020 Daten-Challenge verwendet. Dieser Datensatz umfasst 48 einzelne Zeitserien von Filtern (siehe Bild 2).

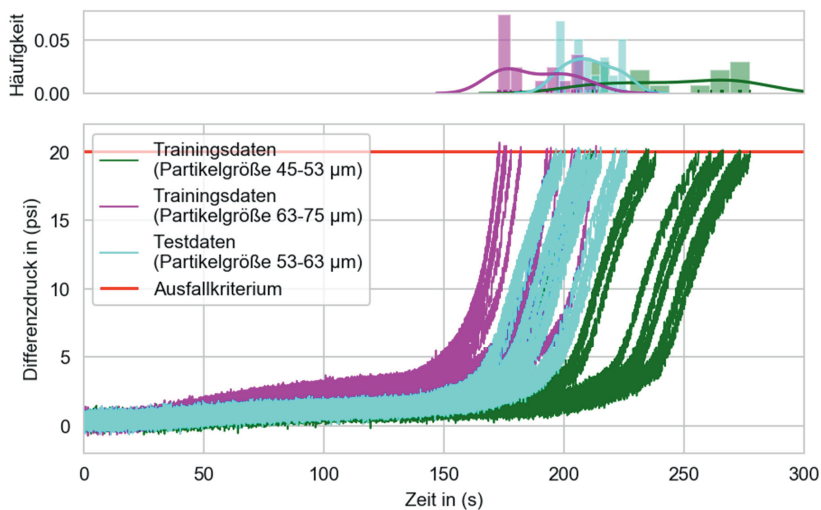


Bild 2: Darstellung der Ausfallhäufigkeitsverteilungen (oberer Teil) sowie der zeitlichen Filterdegradationsverläufe in Abhängigkeit der Zeit und der Partikelgröße

Im Rahmen eines Experiments werden diese auf einem Versuchsprüfstand betrieben, bis es zum Ausfall des Filters kommt. Da die Verstopfung nicht direkt gemessen werden kann, wird als Ausfallkriterium ein Maximalwert für den Differenzdruck am Filter definiert. Überschreitet

der Druckabfall 20 psi (entspricht ca. 1,38 bar) gilt der Filter als verstopft und muss gewechselt werden. Für die Untersuchungen wird eine Lösung bestehend aus Kunststoffpartikeln (PEEK, Dichte  $1,3 \text{ g/cm}^3$ ) und Wasser verwendet. Die Lösung liegt in 12 Zusammensetzungen vor und ergibt sich aus der Kombination der Festkörperverhältnisse (0.4%, 0.43%, 0.45%, 0.48%) mit den Partikelgrößenkategorien (45-53  $\mu\text{m}$ , 53-63  $\mu\text{m}$ , 63-75  $\mu\text{m}$ ). Das Festkörperverhältnis ist die Partikelmasse im Verhältnis zur Masse des Wassers. Somit ergeben sich für jede Zusammensetzung (gleiche Partikelgrößenkategorie und gleiches Festkörperverhältnis) vier gleiche Stichprobendurchläufe. Neben dem Druck vor und nach dem Filter wird außerdem der Volumenstrom gemessen. Alle Größen werden mit einer Abtastrate von 10 Hz aufgezeichnet. Weitere Details zur Systembeschreibung und den verwendeten Komponenten können in [2] und [13] nachgelesen werden. In Anlehnung an die ursprüngliche Aufgabenstellung der Daten-Challenge werden zur Erstellung eines Prognosemodells 32 Zeitreihen verwendet, die alle oben erwähnten Festkörperverhältnisse, jedoch nur zwei Partikelgrößen (45-53  $\mu\text{m}$  und 63-75  $\mu\text{m}$ ) umfassen. Als Testdatensatz dienen die Zeitreihen der Partikelgröße 53-63  $\mu\text{m}$ . Damit wird die Generalisierbarkeit des Modells auf neue, im Training nicht betrachtete, Zeitreihen getestet.

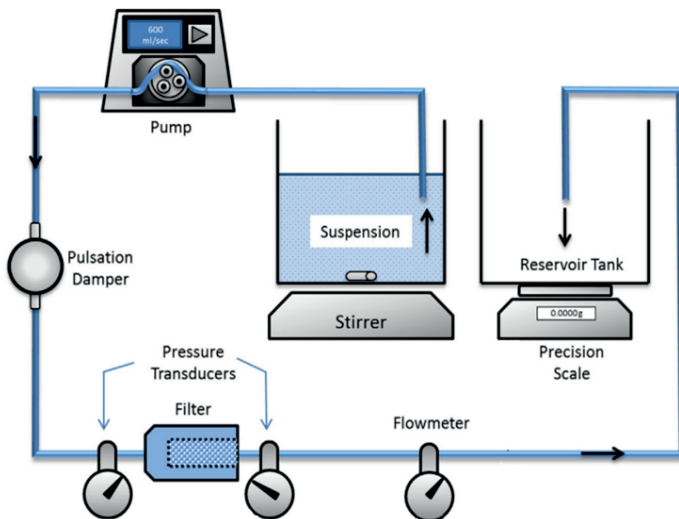


Bild 3: Experimentaufbau [13]

Die Aufgabenstellung besteht folglich aus,

- der Vorhersage des Ausfallszeitpunktes und der nutzbaren Restlebensdauer (Remaining Useful Life, RUL) des Filters zu jedem Zeitpunkt.
- Dabei einen Genauigkeitsverlust zu verhindern, wenn zur Modellbildung nur ein Bruchteil der Trainingsdaten vorhanden ist. Die Genauigkeit wird dabei durch den mittleren absoluten Fehler (Mean Absolute Error, MAE) bewertet.

#### 4. Methodik

Der folgende Abschnitt beschreibt im ersten Schritt das genaue Vorgehen zur Generierung abgeleiteter Merkmale aus den rohen Sensorsignalen, was im Überblick von Bild 4 unter Merkmalsextraktion aufgeführt wird. Anschließend werden im zweiten Schritt die Selektion von relevanten Merkmalen sowie der Trainings- und Validierungsprozess vorgestellt.

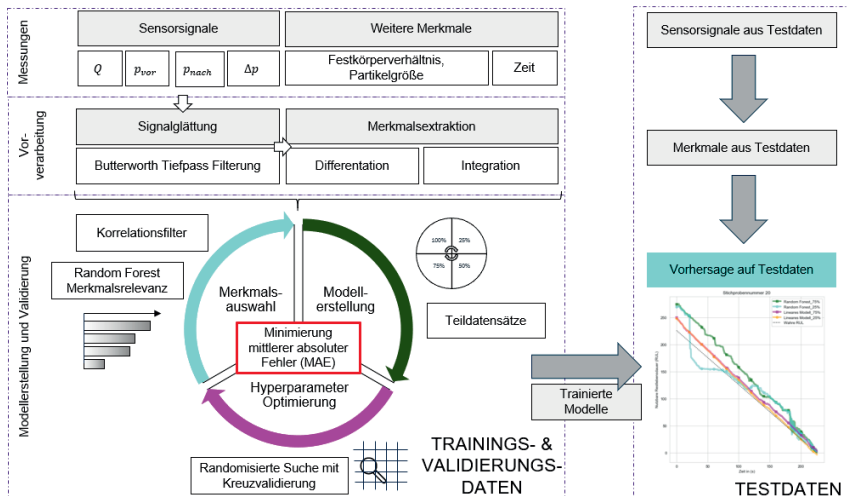


Bild 4: Angewandte Methodik zur Prognosemodellerstellung

Da die gemessenen Sensorsignale ein starkes Rauschen aufweisen, werden alle Eingangsgrößen zunächst durch einen Butterworth Tiefpassfilter vierter Ordnung mit der Grenzfrequenz von 0,3 Hz geglättet. Das Filter soll starke hochfrequente Oszillationen im Signal herausfiltern, den zugrundeliegenden Trend jedoch erhalten. Zur Merkmalsextraktion werden die geglätteten Signale nach der Zeit fünfmal ab und dreimal aufgeleitet. Diese mathematischen Methoden dienen zur Darstellung von Trends und Zusammenhängen höherer Ordnungen in den Signalgrößen. Hier soll insbesondere der zeitliche Verlauf der Druckdifferenz (z.B. Wendepunkte)



charakterisiert werden. Dies ist nötig, da sich der Druckdifferenzverlauf aus unterschiedlichen Bereichen zusammensetzt (zu Beginn näherungsweise linear, zum Ende stark nichtlinear).

### **Merkmalsauswahl**

Die Selektion von Merkmalen ist in datengetriebenen PHM-Systemen von großer Wichtigkeit. Dies liegt zum einen in der Reduktion von Rechenkomplexität begründet. Zum anderen verhindert die gezielte Selektion von Merkmalen eine Anpassung des Modells an Störgrößen, die die Generalisierung negativ beeinflussen können (z.B. in Form einer Überanpassung) [14]. Zur Merkmalsselektion existieren in der Literatur drei Kategorien von Ansätzen die zwischen Filter-Methoden, Wrapper-Methoden und Embedded-Methoden unterscheiden. Filter-Methoden bewerten die Relevanz eines Merkmals anhand eines Informationskriteriums (z.B. Korrelation, Mutual Information, Chi-Square-Test). Diese Methoden sind meist univariat, d.h. sie betrachten lediglich den direkten Zusammenhang zur abhängigen Variablen. Wrapper-Methoden verwenden dagegen eine Untermenge an Merkmalen in Verbindung mit einem Vorhersagemodell (z.B. Recursive Feature Elimination). Embedded-Methoden, darunter auch Random Forest, beinhalten dagegen eine Feature-Selektion bereits im Modellerstellungsprozess und kombinieren damit die Vorteile von Filter und Wrapper-Methoden. Dennoch birgt deren alleiniger Einsatz die Gefahr, dass stark korrelierenden Merkmalen eine niedrigere Relevanz im Vergleich zu unkorrelierten Merkmalen zugesprochen wird.

Um die Modellkomplexität von Vorneherein möglichst gering zu halten, schalten wir 2 Merkmalsselektionsprozesse vor die eigentliche Modellbildung (siehe Bild 4). Dabei werden diejenigen Merkmale aussortiert, die untereinander eine betragsmäßig höhere Pearson-Korrelation als 0.95 aufweisen. Anschließend werden durch einen Random Forest Ansatz 10 Merkmale ausgewählt, die in Bezug auf die Vorhersagegröße (RUL) die höchste Relevanz aufweisen. Die Merkmalsrelevanz wird aus Abnahme des Vorhersagefehlers an den Knoten eines Merkmals, gewichtet mit der Wahrscheinlichkeit diesen Knoten zu erreichen, errechnet. Die Knotenwahrscheinlichkeit ist dabei die Anzahl an Datenpunkten, die diesen Knoten erreichen geteilt durch die Anzahl aller Datenpunkte.

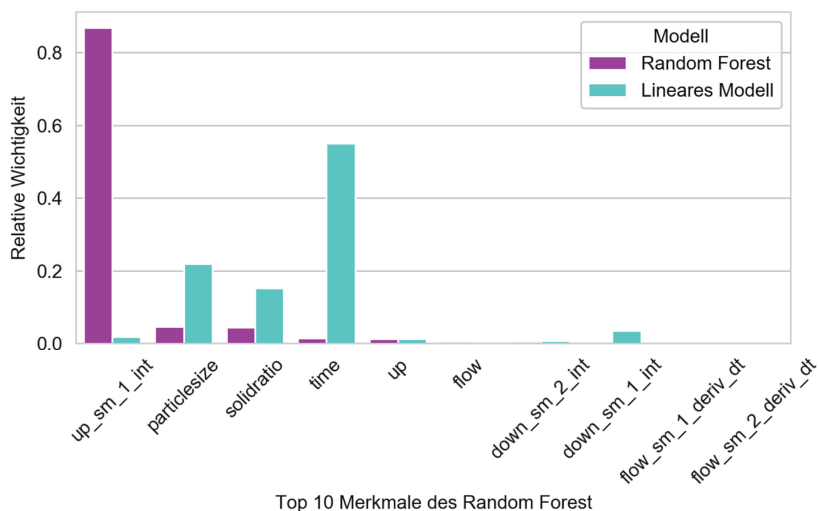


Bild 5: Relative Wichtigkeit der Merkmale für die Vorhersage der Restlebensdauer ausgewählt durch einen Random Forest Ansatz.

Jene 10 Merkmale sind mit ihrer relativen Wichtigkeit (Summe der Relevanz = 1) in Bild 5 dargestellt. Für dieselben Merkmale sind außerdem die Koeffizienten eines linearen Modelles abgebildet, um deren Eignung in Kombination mit anderen Vorhersagemodellen zu prüfen. Es zeigt sich, dass Merkmale, die für ein Modell eine hohe Relevanz aufweisen, nicht zwangsläufig für ein anderes Modell genauso gut geeignet sind.

### Trainings- und Validierungsroutine

Ein generelles Problem bei Machine Learning Modellen ist die Gefahr der Überanpassung an die Trainingsdaten und somit einer mangelnden Generalisierbarkeit auf Testdaten. Um für die vorliegende Problemstellung die optimale Modellkomplexität zu finden, führen wir daher eine Hyperparameteroptimierung durch. Hyperparameter sind in einem Machine Learning Modell Parameter, die modellspezifisch sind und vor dem eigentlichen Trainingsprozess festgelegt werden müssen. Sie bestimmen die Modellkomplexität und können damit den Trainingsprozess maßgeblich beeinflussen. Tabelle 1 dazu zeigt die Hyperparameter sowie deren Werte für die optimierte Modellkomplexität, zugehörig zum jeweiligen Teildatensatz. Die Strategie, welche zur Optimierung angewandt wird, ist die Kombination einer randomisierten Suche mit dreifacher Kreuzvalidierung [15]. Im Gegensatz zur Rastersuche werden dabei jedoch nicht

alle möglichen Parameterkombinationen getestet, sondern durch zufälliges Ziehen eines Wertes aus der Verteilung der einzelnen Hyperparameter. Mit diesen Hyperparameter-Werten wird nun für jeden Teildatensatz ein finales Modell trainiert. Als direkter Vergleich wird ebenfalls für jeden Anwendungsfall ein lineares Modell erstellt.

Tabelle 1: Namen der Hyperparameter und optimierte Werte durch die randomisierte Suche mit Kreuzvalidierung [15]

Hyperparameter (folgen der Benennung aus [9])	100% Trainingsdaten	75% Trainingsdaten	50% Trainingsdaten	25% Trainingsdaten
<i>n_estimators</i> (Anzahl der Schätzer)	13	13	37	37
<i>min_samples_split</i> (Min. Anzahl an Stichproben, die zur Aufteilung an einem Knoten benötigt werden)	6	2	2	10
<i>min_impurity_decrease</i> (Schwellwert für die Varianzreduktion an einem Knoten)	0.0	0.0	0.0	0.0
<i>max_features</i> (Merkmalanzahl bei der Aufteilung eines Knotens)	Auto (alle Merkmale)	Auto	Auto	Auto
<i>max_depth</i> (max. Tiefe des Baumes in Knoten)	25	10	10	20
<i>bootstrap</i> (Stichprobenziehen mit Zurücklegen)	True	True	True	True

Auf Basis der im Training und in der Validierung erzielten Ergebnisse (siehe auch Bild 6), formulieren wir die Hypothese, dass ein Random Forest Modell auch auf stärker abweichenden Testdaten eine bessere Vorhersagegüte erzielt.

## 5. Ergebnisse und Evaluation

Das nachfolgende Kapitel stellt die Ergebnisse vor, die der Random Forest und das lineare Modell auf den Testdaten erzielen. Außerdem ziehen wir daraus Rückschlüsse auf die Eignung des Ansatzes für den zugrundeliegenden Anwendungsfall.

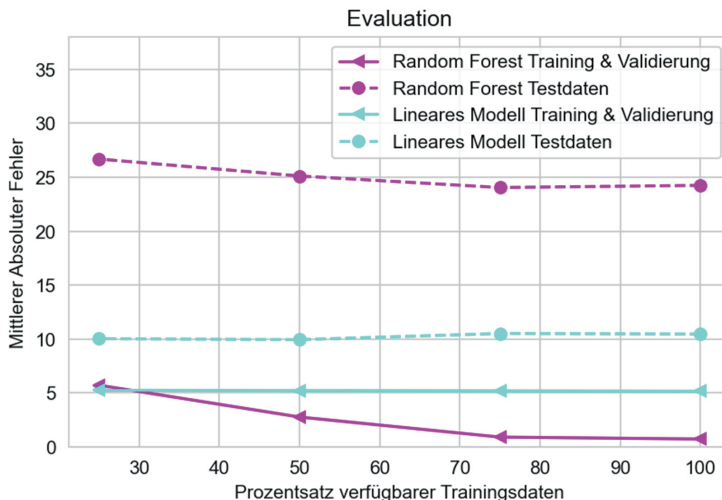


Bild 6: Evaluation mit reduzierten Trainingsdaten

Bild 6 zeigt den mittleren absoluten Fehler (MAE) in Abhängigkeit der zur Verfügung stehenden Trainingsdaten in Prozent. Jeder Markierungspunkt steht dabei für ein trainiertes Modell. Das lineare zeigt keine großen Fehlerschwankungen in Abhängigkeit des verfügbaren Trainingsdatensatzes. Dagegen nimmt der Fehler der Random Forest Modelle ab, je mehr Trainingsdaten verfügbar sind. Betrachtet man jedoch die Fähigkeit zu generalisieren, so wird deutlich, dass das lineare Modell in allen Fällen deutlich besser abschneidet und damit besser generalisiert.

In Bild 7 sind die tatsächliche und geschätzte nutzbare Restlebensdauer beispielhaft von zwei Testzeitreihen für die Modelle Random Forest und lineares Regressionsmodell, trainiert auf 75% und 25% der Trainingsdaten dargestellt. Dabei wird zu jedem Zeitpunkt (alle 0,1 s) eine Vorhersage auf Basis der ermittelten Merkmale aus den Testdaten getroffen. Die beiden Random Forest Modelle folgen qualitativ dem Trend der wahren Restlebensdauer und zeigen nur vereinzelte Ausreißer. Deutlich zu erkennen ist jedoch ein Offset zur wahren Restlebensdauer, der beim linearen Modell deutlich geringer ausfällt. An dieser Stelle macht sich eine inhärente

Eigenschaft des Random Forest besonders bemerkbar. Da an jedem Knoten eine feste Zuordnung zu einem Wert stattfindet, wird durch den jeweiligen Entscheidungsbaum immer derjenige Trainingsdatenpunkt als Referenz ausgewählt, die am besten mit dem vorliegenden Testdatenpunkt übereinstimmt. Eine Interpolation zwischen zwei bekannten Werten wird dadurch, trotz optimierter Modellkomplexität, nicht erreicht. Ebenfalls klar erkennbar ist, dass der Vorhersagefehler zu Beginn der Zeitreihe am größten ist und zum Ende hin immer kleiner wird. Dies entspricht der allgemeinen Erwartung, dass kurzfristige Prognosen eine geringere Abweichung aufweisen als längerfristige.

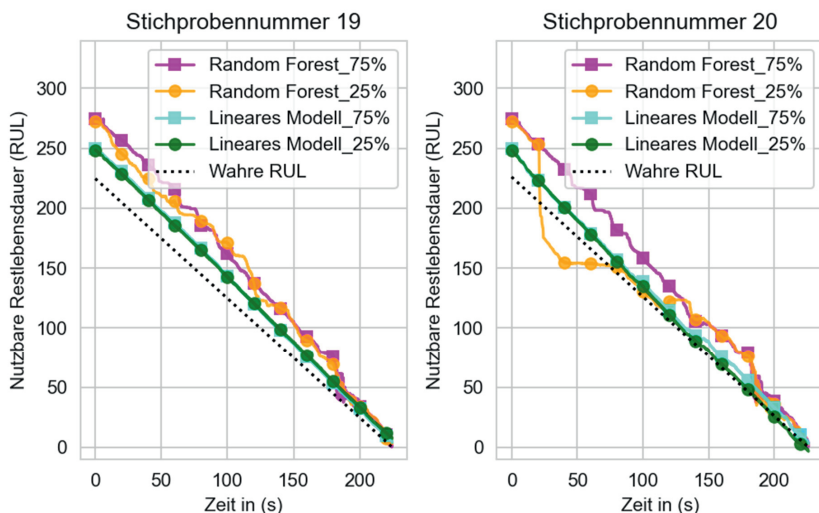


Bild 7: Vergleich der Restlebensdauervorhersage am Beispiel zweier Stichproben

Im gezeigten Anwendungsfall schätzen alle Modelle die nutzbare Restlebensdauer tendenziell als zu groß ein, was aus Sicht des Betreibers und unter Sicherheitsaspekten ein Problem darstellen kann. Für die anderen Zeitreihen sowie den weiteren Modellen (100% und 50% der Trainingsdaten) ergeben sich qualitativ ähnliche Verläufe. Tabelle 2 zeigt eine Gegenüberstellung des MAE auf allen Testzeitreihen mit 50% der Trainingsdaten.

Insgesamt lässt sich dies darauf zurückführen, dass bei Eingangsvariablen, die im Training nur durch wenige kategorische Werte repräsentiert werden, ein Entscheidungsbaum im Fall einer Vorhersage auf unbekannten Datenpunkten nur zwischen den aus dem Training bekannten Kategorien unterscheiden kann. Im Fall der Eingangsvariablen Partikelgrößenverteilung

enthalten die Trainingsdaten nur 2 diskrete Werte, weshalb die Vorhersage mit einer unbekannten Partikelgröße, nur einem Ast dieser 2 bekannten Werte zugeordnet werden kann. Daher schneidet der Random Forest bei der Interpolation bzw. Extrapolation unbekannter Partikelgrößen schlechter ab als ein lineares Modell. Gegenüber Ausreißern kann diese Eigenschaft zwar nützlich sein, für längerfristige und generalisierbare Aussagen zur Schätzung der Restlebensdauer gilt es jedoch den Merkmalsraum möglichst dicht abzudecken.

Tabelle 2: Mittlerer absoluter Fehler (MAE) für einzelne Stichproben. Die Stichprobennummern beziehen sich auf die ursprüngliche Benennung aus [2]

Stichproben Nr.	MAE RF_50%	MAE LM_50%	Stichproben Nr.	MAE RF_50%	MAE LM_50%
17	37.52	21.34	25	19.48	5.02
18	20.64	15.31	26	18.12	3.27
19	34.83	15.38	27	28.72	7.21
20	16.76	7.94	28	17.48	5.13
21	22.34	8.51	29	26.26	4.21
22	36.51	9.89	30	22.17	5.65
23	32.74	17.44	31	8.72	12.73
24	32.77	12.97	32	24.83	4.73

## 6. Fazit

Im vorliegenden Beitrag zeigen wir eine differenzierte und kontextsensitive Betrachtung von Random Forest Modellen für einen Datensatz von Filtrationssystemen. Der Mehrwert dieser Arbeit liegt in der Gegenüberstellung von Random Forest und linearen Modellen in Bezug auf schwach abgedeckte Bereiche in bestimmten Dimensionen des Merkmalsraums in den Trainingsdaten. Die aufgestellte Hypothese, dass ein Random Forest Modell, welches sowohl auf den Trainings- als auch den ungesesehenen Validierungsdaten besser abschneidet, auch bessere Vorhersagen auf stärker abweichenden Testdaten liefert, wurde widerlegt.

Obwohl Kreuzvalidierung und Hyperparameteroptimierung zur Vermeidung einer Überanpassung eingesetzt wurden, zeigen die Ergebnisse den Zielkonflikt zwischen Vorhersagegenauigkeit und Generalisierungsfähigkeit. Für den praxisorientierten Anwender bedeutet dies einerseits, die Eignung der Modelle stetig zu überwachen, wenn neue, sich stark von den Trainings- und Validierungsdaten unterscheidende Merkmalsausprägungen vorliegen. Andererseits gilt es auch das Bewusstsein für das Vertrauen in die datengetriebenen Modelle zu sensibilisieren.

Um die Methodik weiterzuentwickeln, besteht weiterhin Potential in der Berücksichtigung vorangegangener Beobachtungen der Zeitserie bei der Vorhersage. Außerdem kann eine Unsicherheitsquantifizierung dabei unterstützen, die RUL-Vorhersage besser in den Kontext betriebsrelevanter Entscheidungen einzuordnen.

## Literatur

- [1] Heinen, A.; Pietschner, S.; Dorschel, M.; Brömmel, A.: Maßgeschneiderte Vor- und Hauptkraftstofffilterkombinationen für Nfz-Dieselmotoren, Springer-Verlag 2016
- [2] Eker, O.F., Camci, F., Jennions, I.K.: Physics-based prognostic modelling of filter clogging phenomena. *Journal of Mechanical Systems and Signal Processing*, vol. 75 (2016) S. 395 – 412.
- [3] Jones, M.: Engine Fuel Filter Contamination, Boeing Aeromagazine, 2008 [http://www.myboeing.com/commercial/aeromagazine/articles/qtr\\_3\\_08/pdfs/AERO\\_Q308\\_article3.pdf](http://www.myboeing.com/commercial/aeromagazine/articles/qtr_3_08/pdfs/AERO_Q308_article3.pdf), Abgerufen am 10.12.2020
- [4] Ergun, S.: Fluid flow through packed columns. *Chem. Eng. Prog.* 48. 1952
- [5] Ho, T. K.: Random Decision Forests. *Proceedings of the 3rd International Conference on Document Analysis and Recognition*, Montreal, QC, 14–16 August 1995. S. 278–282
- [6] Breiman, L.: Random Forests. *Machine Learning*, Volume 45, (2001), S. 5-32
- [7] Breiman, L.: Bagging predictors. *Machine Learning*, Volume 24, 1996, S. 123 – 140.
- [8] Aslam, J. A.; Popa, R. A.; Rivest, R. L.: On Estimating the Size and Confidence of a Statistical Audit. *EVT*, 2007, S. 8.
- [9] Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R. and Dubourg, V.; Vanderplas, J.; Passos, A.; Cournapeau, D.; Brucher, M.; Perrot, M.; Duchesnay, E.: Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, Volume 12, (2011), S. 2825-2830
- [10] Shalev-Shwartz, S.; Ben-David, S.: *Decision Trees. Understanding Machine Learning.* Cambridge University Press, 2014
- [11] Rokach, L.; Maimon, O.: Top-down induction of decision trees classifiers – a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C.*, 2005.
- [12] Lujan-Moreno, G.; Howard, P.; Rojas, O. G.; Montgomery, D.C.: Design of experiments and response surface methodology to tune machine learning hyperparameters, with a random forest case-study. *Expert Systems with Applications*, 2018. S. 195 – 205
- [13] PHM Europe Data Challenge 2020. <http://phmeurope.org/2020/data-challenge-2020>. Abgerufen am 06.12.2020
- [14] Niu, G.: *Data-Driven Technology for Engineering Systems Health Management*, Science Press Beijing, Springer-Verlag 2017.
- [15] Bergstra, J., Bengio, Y.: Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 2012.



# Untersuchung von Datensätzen und Definition praxisrelevanter Standardfälle im Kontext von Predictive Maintenance

**Fabian Mauthe**, M.Sc., **Marc Hönig**, M.Sc., Prof. Dr.-Ing. **Peter Zeiler**,  
Fakultät Mechatronik und Elektrotechnik/Maschinen und Systeme,  
Hochschule Esslingen, Göppingen

## Kurzfassung

Die Digitalisierung und die damit steigende Datenverfügbarkeit ergibt für Unternehmen wirtschaftliche Potentiale durch vorausschauende Instandhaltung (engl. Predictive Maintenance, PdM), da unter anderem der Lebensdauervorrat eines technischen Systems optimal ausgenutzt werden kann. Für die Umsetzung ist die Kenntnis über die verbleibende Nutzungsdauer (engl. Remaining Useful Life, RUL) notwendig, womit sich die Fachdisziplin Prognostics and Health Management (PHM) beschäftigt. In dem vorliegenden Beitrag wird die Diskrepanz zwischen der Verbreitung und dem Potential von PdM bzw. PHM-Anwendungen diskutiert sowie ein Lösungskonzept erarbeitet. Die darin geforderte notwendige Standardisierung von Datensätzen wird beschrieben und die Vorgehensweise zur Definition von praxisrelevanten Standardfällen wird erläutert. Ergänzend ist eine Übersicht über frei zugängliche Degradationsdatensätze Bestandteil dieses Beitrags, welche den Kompetenzaufbau zur Umsetzung von PHM-Verfahren in Unternehmen zusätzlich erleichtert.

## Abstract

Digitalization and the resulting increase in data availability offer companies economic potential through predictive maintenance (PdM), since, among other things, the lifetime of a technical system can be optimally exploited. For the implementation, knowledge about the remaining useful life (RUL) is necessary, which is the subject of Prognostics and Health Management (PHM). This paper discusses the discrepancy between the spread and the potential of PdM respectively PHM applications and develops a solution concept. The necessary standardization of datasets required is described and the approach for defining practice-relevant standard cases is explained. In addition, an overview of public available degradation datasets is part of this paper, which further facilitates competence increasing for the implementation of PHM processes in companies.

## 1. Einleitung

Die zunehmende Digitalisierung im Rahmen von Industrie 4.0 und der daraus steigende Vernetzungsgrad ergeben für Unternehmen neue wirtschaftliche Potentiale im Bereich vorausschauender Instandhaltung (engl. Predictive Maintenance, PdM) für technische Systeme. Unternehmen können durch PdM unter anderem ihre Instandhaltungs- und Logistikprozesse verbessern oder den Lebensdauervorrat eines technischen Systems optimal ausnutzen [1]. Für PdM sind Kenntnisse über den aktuellen Zustand des Systems und die verbleibende Nutzungsdauer (engl. Remaining Useful Life, RUL) notwendig. Die Disziplin, die sich damit befasst, ist Prognostics and Health Management (PHM). Bei PHM wird anhand von erfassten Degradationsdaten der sich verschlechternde Zustand eines Systems diagnostiziert und die verbleibende Nutzungsdauer prognostiziert, wodurch PdM ermöglicht wird [2, 3]. Zur Diagnose und Prognose werden Methoden eingesetzt, die in datenbasierte, modellbasierte und hybride Methoden unterteilt werden. Gemeinsam haben die Methoden, dass sie alle Degradationsdaten des Systems benötigen [4]. Durch den Einsatz von PHM-Anwendungen, lassen sich für Unternehmen trotz zunächst vorhandenen Kostenaufwänden bei der Entwicklung und Implementierung deutliche Mehrwerte generieren. Unter anderem können Ressourcen durch bedarfsgerechte Instandhaltungsmaßnahmen und die bestmögliche Ausnutzung der tatsächlichen Lebensdauer des Systems eingespart werden. Ergänzt wird dies durch weitere Vorteile in den Bereichen Sicherheit und Verfügbarkeit, da unerwartete Ausfälle durch die Kenntnis über die RUL detektiert werden [5, 6]. Trotz der dargestellten Potentiale und Mehrwerte, ist die Verbreitung und Anwendung von PdM in der Industrie bisher nicht weitläufig und nur auf einzelne, meist kritische Systeme beschränkt [1]. In einer Studie zum Fortschritt von PdM in Unternehmen geben nur 2,7% der Befragten an, die Potenziale bereits ausgeschöpft zu haben. Über 60% der Unternehmen haben hingegen noch keine Aktivitäten unternommen oder befinden sich noch in der Diskussion über mögliche Potenziale ohne ein Pilotprojekt umgesetzt zu haben [7]. Im weiteren Verlauf werden in Kapitel 2 die Ursachen hierfür diskutiert und ein Lösungskonzept erarbeitet. Daraufaufgehend wird in Kapitel 3 die Vorgehensweise zur Definition von Standardfällen, welche praxisrelevante Rahmenbedingungen berücksichtigen, um potentiellen Anwender den Einstieg in die Entwicklung einer PHM-Anwendung zu erleichtern, erläutert. In Kapitel 4 werden öffentlich zugängliche Datensätze, welche zum Kompetenzaufbau und Anwendung einer PHM-Methode dienen können, vorgestellt. Anschließend wird in Kapitel 5 ein Datensatz exemplarisch den Kriterien der Standardfällen gegenübergestellt und in Kapitel 6 wird ein Ausblick gegeben.

## 2. Problemstellung

Dem potentiellen Mehrwert einer PHM-Anwendung stehen aus einer industriellen Betrachtungsperspektive berechnete Hürden gegenüber. Zwar nimmt die Datenverfügbarkeit sowie der Fortschritt in der Entwicklung von Diagnose- und Prognoseverfahren durch die Vielzahl an Veröffentlichungen stetig zu, weiterhin gibt es allerdings eine deutliche Diskrepanz zwischen dem Stand der Forschung und dem Einsatz in der Praxis [8-10]. Die Gründe für die Diskrepanz sind vielschichtig und werden im kommenden Abschnitt diskutiert. Resultierend daraus wird ein Lösungskonzept erarbeitet.

### 2.1 Ursachen der geringen industriellen Verbreitung

Bei der Umsetzung von PHM entstehen Implementierungskosten sowie Kosten für den Kompetenzaufbau, welche für die Unternehmen eine Hemmschwelle darstellen. Notwendig für die Umsetzung sind ausreichend Degradationsdaten, welche unter möglichst praxisnahen Bedingungen erzeugt werden sowie ein hohes interdisziplinäres Know-how [3, 8]. Für eine vollumfängliche Entwicklung einer PHM-Anwendung sind fundierte Kenntnisse aus den Bereichen Sensorik, Datenvorverarbeitung, Statistik, maschinelles Lernen, künstliche Intelligenz, Wirk- und Ausfallmechanismen sowie Zuverlässigkeitstechnik notwendig [4]. Um Unternehmen bei der Auswahl geeigneter Prognoseverfahren zu unterstützen, existieren Auswahlmethodiken wie [11], diese berücksichtigen jedoch nur in einem geringen Maße praxisrelevante Rahmenbedingungen, weshalb sie nur sehr begrenzt eingesetzt werden können.

In der Literatur werden meist ideale, vollumfängliche Datensätze angenommen, was häufig nicht den Datensätzen aus der Praxis entspricht, da hier Einschränkungen bspw. beim Datenumfang und der Qualität vorliegen. Die Gründe hierfür sind insbesondere der hohe Kostenaufwand bei der Erzeugung der Daten bis zum Systemausfall sowie Aspekte wie Vertraulichkeit und Unternehmensgeheimnisse, welche die freie Zugänglichkeit beschränken [12]. Des Weiteren verwenden viele Veröffentlichungen als Benchmark die identischen öffentlich zugänglichen, speziell für diesen Zweck unter Laborbedingungen erzeugten, Degradationsdatensätze.

Die mangelnde Datenvielfalt, die begrenzte praxisnahe Datenmenge und die fehlende Praxisrelevanz der Auswahlmethodiken hindern in Unternehmen den Kompetenzaufbau für PHM und folglich auch die Verbreitung von PdM.

### 2.2 Lösungskonzept

Ein Lösungskonzept für die beschriebene Problemstellung ist eine praxisrelevante Auswahlmethodik für Prognoseverfahren. Durch die Auswahlmethodik kann der Einstieg in PHM erleichtert und der Kompetenzaufbau unterstützt werden. Für die Auswahlmethodik sind defi-

nierte Standardfälle notwendig, die die Datensituation des Degradationsverlaufs eines Systems repräsentieren. Sie berücksichtigen dabei praxisrelevante Rahmenbedingungen und dienen zur Beschreibung der Charakteristik der vorliegenden Degradationsdaten. Die Standardfälle werden als Abstraktion der Datensituationen verstanden und können vielfältig eingesetzt werden. Mittels eines Standardfalls kann basierend auf der betrachteten Datencharakteristik ein geeignetes Prognoseverfahren für die geplante PHM-Anwendung ausgewählt werden ohne dieses anhand der Degradationsdaten empirisch zu ermitteln. Ebenfalls können PHM-Anwendungen von Produkten oder Systemen mit ähnlicher Datencharakteristik schematisch projiziert werden, wodurch Kompetenzen aufgebaut und Entwicklungs- und Ressourcenaufwände reduziert werden können. Ergänzend zur Auswahlmethodik gilt es den potentiellen PHM-Anwendern ein Überblick über bereits vorhandene und öffentlich zugänglichen Degradationsdatensätze zu geben. Anhand der Standardfälle können die Datensätze bewertet und charakterisiert werden. Dadurch können Datensätze mit ähnlicher Charakteristik zur Entwicklung einer exemplarischen PHM-Anwendung genutzt werden. Bei einer Neuentwicklung eines Systems kann ein Datensatz mit ähnlicher Charakteristik zum Kompetenzaufbau dienen, wodurch die Entwicklung einer PHM-Anwendung erleichtert wird.

### **3 Vorgehensweise zur Definition von Standardfällen**

Die Definition von Standardfällen erfolgt auf der Grundlage von praxisrelevanten Rahmenbedingungen. Zunächst wird ein Abstraktionsschema erarbeitet, welches die Definition sowie die Übersichtlichkeit der relevanten Kriterien der Standardfälle erleichtert. Außerdem können die Standardfälle anhand des Schemas eindeutig separiert werden. Anschließend werden die relevanten Kriterien der Standardfälle, welche die inhaltlichen Aspekte definieren, erläutert.

#### **3.1 Abstraktionsschema**

Ziel des Schemas ist, die verfügbaren Datenlagen der Degradation eines technischen Systems zu abstrahieren und diese in einer Struktur abzubilden, welche die Zuordnung des Systems bzw. dessen Degradationsdaten zu definierten Standardfällen ermöglicht. Die Abstraktion wird durch die Definition von Hauptkriterien und der dazugehörigen Unterkriterien realisiert. In der Abbildung 1 ist das Abstraktionsschema dargestellt.

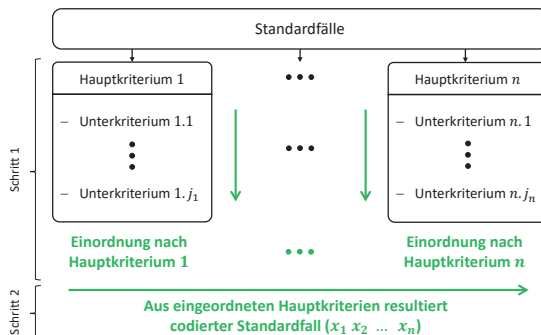


Abbildung 1: Abstraktionsschema

Es ist ersichtlich, dass die Standardfälle aus  $n$  Hauptkriterien bestehen, welche wiederum eine jeweils individuelle Anzahl Unterkriterien ( $j_i, i = 1, \dots, n$ ) beinhalten. Die Unterkriterien können dabei anhand von Ausprägungen individuell weiter untergliedert werden. Für die Nutzung des Schemas ist ein zweistufiges Vorgehen notwendig. In der ersten Stufe wird aus den jeweiligen Unterkriterien ( $x_{i,1}, \dots, x_{i,j_i}$ ) innerhalb jedes Hauptkriteriums  $i$  eine entsprechende Einordnung ( $x_i$ ) gebildet. Nach der Abbildung 1 entspricht dies den vertikalen Einordnungen (Schritt 1). In der zweiten Stufe wird aus den  $n$  Einordnungen der ersten Stufe, welche die Informationen der Unterkriterien beinhalten, ein codierter Standardfall ( $x_1, \dots, x_n$ ) gebildet. Dies entspricht in der obigen Abbildung der horizontalen Einordnung (Schritt 2). Die Codierung eines Standardfalls besteht folglich aus einem Zeilenvektor mit  $n$  Elementen, welche alle gleichgewichtet sind. Dies bedeutet, dass die Reihenfolge der Hauptkriterien keiner Wertung entspricht.

Die Unterkriterien können dabei quantitativ oder qualitativ ausgeprägt sein, wobei in diesem Kontext häufig binäre Ausprägungen auftreten können. Für die eindeutige Unterscheidung und Klassifikation der Standardfälle sind solche Ausprägungen vorteilhaft, da daraus eindeutige Unterscheidungskriterien resultieren. Quantitative Ausprägungen bieten den Vorteil, dass ein Kriterium bzw. ein Standardfall zu einem Bereich zugeordnet werden kann.

### 3.2 Kriterien der Standardfälle

Um eine allgemeine Gültigkeit sowie die Praxisrelevanz der Standardfälle zu gewährleisten, wird eine weitsichtige und vielfältige Analyse der möglichen Datensituationen eines technischen Systems durchgeführt. Resultierend daraus ergeben sich Kriterien, mit denen das zuvor gezeigte Abstraktionsschema gefüllt wird. Die nachfolgende Tabelle zeigt die sechs definierten Hauptkriterien sowie die dazugehörigen Unterkriterien mit den jeweiligen Ausprägungen.

Tabelle 1: Kriterien der Standardfälle für PHM-Anwendungen

1. Historie der Daten	2. Degradationserfassung	3. Degradationsdaten
1.1 Datenhistorie <ul style="list-style-type: none"> <li>- Run-to-failure (<math>HI = 1 \rightarrow 0</math>)</li> <li>- Run-to-threshold (<math>HI = 1 \rightarrow thres</math>)</li> <li>- Start während Lebenszyklus (<math>HI = x_{start} \rightarrow 0 \vee thres</math>)</li> <li>- Keine Historie</li> </ul> 1.2 System mit Wartung + Neustart           1.3 Lebensdauerkriterium <ul style="list-style-type: none"> <li>- Liegt vor/nicht vor</li> </ul>	2.1 Aufzeichnung <ul style="list-style-type: none"> <li>- Kontinuierlich</li> <li>- Periodisch</li> <li>- Zufällig</li> <li>- Zustandsabhängig</li> </ul> 2.2 Messeigenschaften der Aufzeichnung <ul style="list-style-type: none"> <li>- Abtastrate</li> <li>- Zeitinformation               <ul style="list-style-type: none"> <li>• Gesamtbetriebszeit</li> <li>• Anzahl der Aufzeichnung</li> </ul> </li> </ul>	3.1 Degradations- <ul style="list-style-type: none"> <li>- beeinflusste Daten</li> <li>- beeinflussende Daten</li> </ul> 3.2 Degradationsinformation <ul style="list-style-type: none"> <li>- Direkt</li> <li>- Indirekt</li> </ul> 3.3 Vorkenntnisse <ul style="list-style-type: none"> <li>- Degradationsmerkmal</li> <li>- Degradationsprozess</li> </ul> 3.4 Reproduzierbarkeit der Daten <ul style="list-style-type: none"> <li>- Streuung der Messreihen</li> </ul>
4. Systeminformationen	5. Qualität & Quantität der Daten	6. Datenursprung
4.1 Betriebszustand <ul style="list-style-type: none"> <li>- Konstant</li> <li>- Deterministisch</li> <li>- Stochastisch</li> </ul> 4.2 Ausfall System <ul style="list-style-type: none"> <li>- 1 Mechanismus / x Mechanismen</li> <li>- 1 Bauteil / x Bauteile</li> </ul> 4.3 Motivation PHM-Betrachtung <ul style="list-style-type: none"> <li>- Sicherheit</li> <li>- Verfügbarkeit</li> <li>- Wirtschaftlichkeit</li> </ul> 4.4 Redundanz	5.1 Zustandsraum <ul style="list-style-type: none"> <li>- Relevanter Zustandsraum               <ul style="list-style-type: none"> <li>• Vollständig/Unvollständig</li> </ul> </li> <li>- Erweiterter Zustandsraum</li> </ul> 5.2 Datenmenge <ul style="list-style-type: none"> <li>- Gesamtanzahl an Daten</li> <li>- Anzahl an Daten je Zustand</li> </ul> 5.3 Datenqualität <ul style="list-style-type: none"> <li>- Systematische Messfehler</li> <li>- Zufällige Messfehler</li> </ul>	6.1 Ursprung <ul style="list-style-type: none"> <li>- Simulation</li> <li>- Laborversuche               <ul style="list-style-type: none"> <li>• Beschleunigt/nicht beschleunigt</li> </ul> </li> <li>- Realer Betrieb               <ul style="list-style-type: none"> <li>• Ausgewählter Prüfling</li> <li>• Zufälliger Prüfling</li> </ul> </li> </ul>

### 3.2.1 Historie der Daten

Die Historie der Daten mit deren aufgeführten Unterkriterien Datenhistorie, System mit Wartung und Neustart sowie Lebensdauerkriterium bestimmen maßgeblich die Klassifizierung eines Standardfalls anhand vorhandener Daten.

Das Unterkriterium Datenhistorie beschreibt die Ausprägung an Zuständen des Systems, welche die Daten beinhalten. Dabei werden vier wesentliche Datenlagen betrachtet. Zur Quantifizierung des Zustands, wird der sogenannte Health Index (HI), welcher im Wertebereich  $[0; 1]$  liegt, verwendet [8]. Ist der  $HI = 1$ , dann liegt noch keine Degradation vor bzw. kann am Betrachtungszeitpunkt nicht erfasst werden. Wenn der  $HI = 0$  ist, liegt eine vollständige Degradation vor, was einem Systemausfall gleichgestellt ist.

Das zweite Unterkriterium berücksichtigt ein System mit Wartung und anschließendem Neustart. Bei solchen Systemen kommt es zu einem Anstieg beim HI. Des Weiteren gilt zu beachten, dass der HI nach der Wartung nicht dem eines neuwertigen Systems ( $0 < HI < 1$ ) entspricht.

Im dritten Unterkriterium wird das Lebensdauerkriterium des technischen Systems betrachtet. Liegt dies vor, können die Aspekte Ausfall und Grenzwert definiert und bspw. durch einen entsprechenden HI repräsentiert werden.

### 3.2.2 Degradationserfassung

Bei der Degradationserfassung werden die zeitlichen Ausprägungen der einzelnen Messreihen analysiert. Im ersten Unterkriterium wird die Aufzeichnung der Degradation und deren zeitliche Kontinuität unterschieden. Zu beachten gilt, dass hier die zeitliche Kontinuität im Kontext der Lebensdauer zu verstehen ist und nicht im Kontext der Messdatenerfassung. Liegt keine oder nur periodische Kontinuität vor, liegen die Degradationsdaten nur zu diskreten Zeitpunkten vor und es kann kein kontinuierlicher Degradationsverlauf abgebildet werden. Die Einflüsse der diskreten Messdatenerfassung werden dahingegen im Unterkriterium 2.2 berücksichtigt.

Bei einer kontinuierlichen Aufzeichnung werden die Degradationsdaten parallel zum Betrieb des Systems erfasst und liegen über die Lebensdauer lückenlos vor. Liegen zeitliche aber konstante Abstände zwischen den jeweiligen erfassten Degradationsdaten vor, dann liegt eine periodische Aufzeichnung vor. Hier werden bspw. definierte Prüfzyklen realisiert, anhand derer der aktuelle Degradationszustand erfasst wird. Ein weiterer Anwendungsfall dieser Aufzeichnung liegt im Bestreben die Datenmengen zu reduzieren, was durch die periodische Aufzeichnung realisiert wird. Der wesentliche Unterschied der zufälligen Aufzeichnung dazu liegt in unterschiedlichen zeitlichen Abständen der Degradationserfassung, was mit einer zufälligen Stichprobe gleichgestellt werden kann. In diesem Fall kommt es zu zeitlichen und wertemäßigen Änderungen im aufgezeichneten Degradationsverlauf. Neben den bisherigen zeitabhängigen Aufzeichnungen, werden die zustandsabhängigen Aufzeichnungen ebenfalls berücksichtigt. Bei dieser Aufzeichnungsart liegen Degradationsdaten in Abhängigkeit eines definierten Zustands des Systems vor. Zu beachten ist hier, dass die Degradationsmessung kontinuierlich sein kann, die Daten allerdings nur aufgezeichnet, also gespeichert werden, wenn ein veränderter Zustand detektiert wird. Die zustandsabhängige Aufzeichnung kann mit der Verwendung eines Aufzeichnungstriggers realisiert werden. Mit dieser Aufzeichnung kann einerseits ebenfalls die Datenmenge reduziert werden und andererseits die Aufzeichnung von Daten bei nur geringen oder keinen Zustandsänderungen vermieden werden.

Das zweite Unterkriterium beinhaltet die Messeigenschaften jeder Aufzeichnung. Bestandteil davon ist die Abtastrate sowie die Zeitinformation der Messdatenaufzeichnung. Bei periodischen oder zufälligen Aufzeichnungen ist die Zeitinformation als weitere Ausprägung relevant. Darunter wird die zeitliche Einordnung der jeweiligen Aufzeichnung verstanden, ob diese der Lebensdauer zuordenbar ist oder nicht. Am Beispiel eines Prüfzyklus würde die Gesamtzyklenanzahl neben der Prüfzyklenanzahl ebenfalls bekannt sein, wenn eine Zeitinformation vorliegt.

### 3.2.3 Degradationsdaten

Beim dritten Hauptkriterium wird die Degradation bzw. deren Daten eines technischen Systems detailliert betrachtet, woraus sich vier Unterkriterien ergeben.

Die Art der erfassten Degradationsdaten wird in degradationsbeeinflusste und in degradationsbeeinflussende Daten unterschieden, allerdings können beide in Degradationsdaten vorhanden sein. Degradationsbeeinflusste Daten sind Daten, welche die Auswirkungen der Degradation widerspiegeln und als Indikator eingesetzt werden können. Typische Beispiele sind unter anderem Vibrations- oder Temperaturdaten, anhand derer der Degradationsfortschritt (z.B. HI, RUL) ermittelt werden kann. Für die individuelle Einschätzung des aktuellen Zustands sind diese Daten notwendig. Degradationsbeeinflussende Daten sind Daten, welche das Degradationsverhalten beeinflussen. Typische Beispiele sind unter anderem Belastungsdaten, Laufzeit, Prozessdaten oder Betriebsbedingungen.

Das Unterkriterium Degradationsinformation beschreibt die Ermittlung des Degradationszustands, welche direkt oder indirekt durchgeführt werden kann. Bei einer direkten Ermittlung kann der Degradationszustand direkt aus den aufgezeichneten Daten ermittelt werden. Gängige Beispiele sind unter anderem Rissfortschritts- oder Verschleißmessungen [13]. Bei einer indirekten Ermittlung kann der Degradationszustand nicht direkt aus den aufgezeichneten Daten ermittelt werden. Es ist ein zusätzlicher Bearbeitungsschritt notwendig, um eine Korrelation zwischen den Messwerten und dem Systemzustand zu erhalten. Anhand des Systemzustands kann der Degradationszustand ermittelt werden. Gängige Beispiele sind unter anderem Vibrations- oder Temperaturmessungen, wie sie bspw. bei Wälzlagern zum Einsatz kommen [14].

Das dritte Unterkriterium berücksichtigt die Vorkenntnisse über das degradierende System sowie des betrachteten Degradationsprozesses. Dazu gehören Degradationsmerkmale wie bspw. Features oder HIs, die bei der Ermittlung des Degradationszustands notwendig sind, sowie Kenntnisse über den Degradationsprozess. Liegen Degradationsmerkmale bereits vor, dann sind die im Unterkriterium 3.2 genannten Degradationsinformationen bereits ermittelt. Die Ausprägung Degradationsprozess berücksichtigt die Verfügbarkeit eines physikalischen Modells oder einer mathematischen Funktion, welches die Degradation bzw. den Degradationsverlauf beschreibt.

Beim vierten Unterkriterium wird die Reproduzierbarkeit der Daten bzw. des Degradationsverlaufs betrachtet. Hierbei wird die Streuung der einzelnen Messreihen bei gleichbleibenden Betriebsbedingungen bewertet und eingeordnet. Dabei werden unter anderem fertigungstechnische Toleranzen des technischen Systems berücksichtigt, welche zu unterschiedlichen Degradationen führen.



### 3.2.4 Systeminformation

Das erste Unterkriterium Betriebszustand beschreibt die Abfolge von Betriebszuständen während der Lebensdauer eines Systems. Als konstant gilt ein Betriebszustand, wenn über die Lebensdauer keine Änderungen vorhanden sind. Liegen während der Lebensdauer immer wiederkehrende gleiche, also mehrere jeweilige konstante Betriebszustände vor, dann sind dies deterministische Betriebszustände. Da in dem Kontext des Unterkriteriums die Ausprägung der Betriebszustände betrachtet wird, gilt es zu beachten, dass mehrere konstante Betriebszustände deren zeitliche Reihenfolge allerdings zufällig ist, ebenfalls zu den deterministischen Betriebszuständen zählen. Stochastische Betriebszustände sind hingegen zufällig bzgl. deren Ausprägungen der Betriebszustände. Besonders bei deterministischen und stochastischen Betriebszuständen ergibt sich eine enge Wechselwirkung mit dem bereits erwähnten Unterkriterium 3.1, da durch die degradationsbeeinflussenden Daten die Betriebszustände quantifiziert werden können.

Das zweite Unterkriterium betrachtet die Anzahl an Bauteilen sowie die mögliche Anzahl an Ausfallmechanismen, welche zur Degradation oder zu einem Ausfall eines Systems führen. Die Ausfallmechanismen beschreiben mögliche Ausfallursachen eines Bauteils, die Anzahl an Bauteilen wiederum gibt an, wie viele Bauteile mit entsprechender Anzahl an Ausfallmechanismen für einen Ausfall des Systems relevant sind.

Im dritten Unterkriterium wird die Motivation der PHM-Betrachtung eines technischen Systems betrachtet. Diese können in der Sicherheit, Verfügbarkeit oder Wirtschaftlichkeit liegen [4].

Das vierte Unterkriterium berücksichtigt Redundanzen im Gesamtsystem. Darunter wird im Falle einer sogenannten heißen Redundanz berücksichtigt, dass es zu sprunghaften Änderungen der Systembelastung kommen kann oder aus einem Ausfall des betrachteten Systems kein Gesamtausfall resultiert.

### 3.2.5 Qualität & Quantität der Daten

Das erste Unterkriterium beschreibt die Datenverfügbarkeit des Systems in Bezug auf den Zustandsraum. Darin wird analysiert, inwiefern der relevante Zustandsraum mit den Daten eines Systems abgedeckt ist. Besonders von Bedeutung wird dies, wenn bei dem betrachteten System die zuvor definierten deterministischen bzw. stochastischen Betriebszustände vorliegen oder die Anzahl an Bauteilen bzw. Ausfallmechanismen bekannt sind. Werden diese Zustände durch Daten des Systems abgedeckt, ergibt sich ein relevanter Zustandsraum. Unter einem erweiterten Zustandsraum werden Datenlagen verstanden, die Zustände beinhalten, welche nicht im realen Betrieb des Systems vorgesehen sind. Diese können bspw. durch beschleunigte Laborversuche generiert werden.

Das zweite Unterkriterium erfasst die vorhandene Datenmenge. Beachtet werden hierbei die Gesamtanzahl an vorhandenen Daten sowie die Anzahl an Daten je Zustand.

Das dritte Unterkriterium beinhaltet vorhandene Messfehler in den Systemdaten. Dabei wird zwischen systematischen und zufälligen Messfehlern unterschieden. In diesem Kontext wird die Qualität der Messung betrachtet und nicht die Qualität des Systems wie im Unterkriterium 3.4.

### **3.2.6 Datenursprung**

Im sechsten Hauptkriterium wird der Datenursprung eines Systems betrachtet. Die Daten können aus einer Simulation, aus Labor- und Prüfstandsversuchen oder aus dem realen Betrieb stammen.

Bei diesem Haupt- bzw. Unterkriterium handelt es sich um Zusatzinformationen, welche mit einigen zuvor genannten Kriterien in Verbindung stehen. Wird eine Simulation betrachtet, dann können Betriebszustände eindeutig eingehalten werden und Messfehler können zwar künstlich erzeugt werden, existieren grundsätzlich aber nicht. Labor und Prüfstandsversuche sind hier realistischer, beinhalten aber noch nicht alle Einflussfaktoren im Vergleich zu Daten aus dem realen Betrieb [8]. Zusätzlich muss beachtet werden, ob die Labor- und Prüfstandsversuche beschleunigt durchgeführt wurden, da dies häufig durch abweichende Betriebszustände realisiert wird [15]. Bei der Betrachtung der Daten aus dem realen Betrieb ergibt sich die Unterscheidung bei der Auswahl des entsprechenden Prüflings. Ausgewählte Prüflinge entsprechen einem bewusst im realen Betrieb eingesetztem System, welches bspw. die Betriebsgrenzen des Systems ausreizt, wie es bei Extremtests von Fahrzeugen vorkommt. Werden zufällig Prüflinge aus der Grundgesamtheit gewählt, können in Abhängigkeit der statistischen Verteilung die meisten realen Daten gesammelt werden.

## **4 Datensätze**

PHM-Verfahren können ausschließlich anhand von Degradationsdaten erforscht und entwickelt werden, weshalb die Verfügbarkeit dieser Daten essenziell ist [4, 8]. In der Literatur stehen freizugängliche Datensätze zur Verfügung, die zum Kompetenzaufbau und als Benchmark bei der Entwicklung von Verfahren verwendet werden können [8, 12].

Im Kontext von PHM sind zwei entscheidende Quellen für frei zugängliche Datensätze zu erwähnen. [8] Dabei handelt es sich um die PHM Society [16] sowie das Prognostics Center of Excellence (PCoE) des NASA Ames Research Centers [17]. Im Zuge von Data Challenges der PHM Society sind 15 frei zugängliche Degradationsdatensätzen entstanden und verfügbar. Das PCoE bietet ein Daten Repository für Prognosetechnologien, in dem es 15 frei zugängliche Datensätze bereitstellt. In Summe ergeben sich aus diesen zwei Quellen 30

Datensätze. Doppelnennungen sind vorhanden, da einige Datensätze des PCoE zwar im Rahmen von PHM Data Challenges verwendet wurden, diese sich im Umfang und Aufbau jedoch unterscheiden. Ebenfalls wird eine relevante Datensammlung des Fraunhofer-Instituts für Produktionstechnologie IPT berücksichtigt, welche relevante Datensätze für maschinelles Lernen in der Produktion aufführt [18].

Nennenswerte Plattformen sind die Onlinecommunity Kaggle [19] mit 7 relevanten Datensätzen und das Repository der University of California in Irvine (UCI) [20] mit 5 Datensätzen. Ergänzt wird die Sammlung mit jeweils einem Datensatz von der Universität Paderborn, zenodo [21], OpenML [22], OpenEI [23], Mendeley Data [24] sowie einem Datensatz, der über GitHub [25] zur Verfügung steht. Die Recherche auf der Plattformen OpenAI [26] ergibt keinen weiteren relevanten Datensatz. Zu beachten ist, dass Datensätze auf mehreren Plattformen zur Verfügung stehen können, hier allerdings nur einmalig berücksichtigt werden. Die folgende Tabelle zeigt die Übersicht aller 48 relevanten Datensätze und gibt die entsprechende Quelle bzw. Plattform an, unter der der jeweilige Datensatz zu finden ist. Eine detailliertere Beschreibung sowie der Link zu den Datensätzen ist in [27] zu finden.

Tabelle 2: Übersicht frei zugängliche Degradationsdatensätze

Nr.	Datensatz	Nr.	Datensatz
1	Aircraft Engine - PHM Data Challenge 2008	25	MOSFET Thermal Overstress Aging - NASA PCoE
2	Gearbox Fault Detection - PHM Data Challenge 2009	26	Capacitor Electrical Stress 2 - NASA PCoE
3	Milling Machine - PHM Data Challenge 2010	27	HIRF Battery Data Set - NASA PCoE
4	Anemometer Fault Detection - PHM Data Challenge 2011	28	Small Satellite Power Simulation - NASA PCoE
5	FEMTO Bearing Data Set - PHM Data Challenge 2012	29	Algae Raceway Data Set - NASA PCoE
6	unknown - PHM Data Challenge 2013	30	Turbofan Engine Degradation Simulation 2 - NASA PCoE
7	unknown - PHM Data Challenge 2014	31	APS Failure at Scania Trucks - Kaggle
8	Fuel Cell - PHM IEEE Data Challenge 2014	32	Production Plant Data for Condition Monitoring - Kaggle
9	Plant Fault Detection - PHM Data Challenge 2015	33	CNC Mill Tool Wear - Kaggle
10	Semiconductor CMP - PHM Data Challenge 2016	34	Versatile Production - Kaggle
11	Bogie Vehicle - PHM Data Challenge 2017	35	Genesis Demonstrator - Kaggle
12	Waver Manufacturing - PHM Data Challenge 2018	36	Predictive Maintenance - Kaggle
13	Fatigue cracks - PHM Data Challenge 2019	37	One Year Industrial Component Degradation - Kaggle
14	Filtration System - PHME Data Challenge 2020	38	Steel Plates Faults - UCI
15	intend to prepare - PHME Data Challenge 2021	39	Maintenance of Naval Propulsion Plants - UCI
16	NASA Milling - NASA PCoE	40	Mechanical Analysis - UCI
17	Li-ion Battery Aging - NASA PCoE	41	Robot Execution Failures - UCI
18	Bearing Data Set - NASA PCoE	42	Condition monitoring of hydraulic systems - UCI
19	Turbofan Engine Degradation Simulation - NASA PCoE	43	Bearing Damage - University Paderborn
20	CFRP Composites Data Set - NASA PCoE	44	Azure Blob - GitHub
21	IGBT Accelerated Aging Data Set - NASA PCoE	45	Gearbox Fault Diagnosis - OpenEI
22	Trebuchet - NASA PCoE	46	Bolts - OpenML
23	Randomized Battery Usage - NASA PCoE	47	Predictive maintenance dataset - zenodo
24	Capacitor Electrical Stress - NASA PCoE	48	Diesel Engine Faults - Mendeley Data

## 5 Anwendungsbeispiel und kritische Betrachtung

Im Folgenden wird exemplarisch der Datensatz „Aircraft Engine – PHM Data Challenge 2008“ [28] anhand der Kriterien der Standardfälle eingeordnet sowie anschließend kritische Aspekte bei der Einordnung des Datensatzes erläutert. Detaillierte Informationen zum Datensatz sowie dem darin verwendeten Simulationsmodell sind in [29] enthalten. Die Tabelle 3 zeigt die eingeordneten Kriterien für Standardfälle.

Tabelle 3: Anwendungsbeispiel Datensatz „Aircraft Engine – PHM Data Challenge 2008“

1. Historie der Daten	2. Degradationserfassung	3. Degradationsdaten
1.1 Datenhistorie <ul style="list-style-type: none"> <li>- <b>Start während Lebenszyklus, Ende Systemausfall</b> (<math>H(t) = x_{start} \rightarrow 0</math>)</li> </ul> 1.2 System mit Wartung + Neustart <ul style="list-style-type: none"> <li>- <b>nein</b></li> </ul> 1.3 Lebensdauerkriterium <ul style="list-style-type: none"> <li>- <b>Liegt vor</b></li> </ul>	2.1 Aufzeichnung <ul style="list-style-type: none"> <li>- <b>Periodisch (pro Betriebszyklus liegt eine Momentaufnahme vor)</b></li> </ul> 2.2 Messeigenschaften der Aufzeichnung <ul style="list-style-type: none"> <li>- <b>Abstrakte unbekannt (Momentaufnahme)</b></li> <li>- <b>Gesamtbetriebszeit bekannt</b></li> </ul>	3.1 Degradations- <ul style="list-style-type: none"> <li>- <b>beeinflusste + beeinflussende Daten (21 Sensoren)</b></li> </ul> 3.2 Degradationsinformation <ul style="list-style-type: none"> <li>- <b>Indirekt</b></li> </ul> 3.3 Vorkenntnisse <ul style="list-style-type: none"> <li>- <b>Keine Degradationsmerkmale</b></li> <li>- <b>Simulationsmodell + exponentieller Degradationsverlauf [29]</b></li> </ul> 3.4 Reproduzierbarkeit der Daten <ul style="list-style-type: none"> <li>- <b>Variabler Anfangsver-schleiß</b></li> </ul>
4. Systeminformationen	5. Qualität & Quantität der Daten	6. Datenursprung
4.1 Betriebszustand <ul style="list-style-type: none"> <li>- <b>Deterministisch, Abfolge unbekannt</b></li> </ul> 4.2 Ausfall System <ul style="list-style-type: none"> <li>- <b>x Mechanismen, x Bauteile</b></li> </ul> 4.3 Motivation PHM-Betrachtung <ul style="list-style-type: none"> <li>- <b>Unbekannt</b></li> </ul> 4.4 Redundanz <ul style="list-style-type: none"> <li>- <b>Keine Information (Nein)</b></li> </ul>	5.1 Zustandsraum <ul style="list-style-type: none"> <li>- <b>Relevanter Zustandsraum</b></li> <li>- <b>Vollständig</b></li> </ul> 5.2 Datenmenge <ul style="list-style-type: none"> <li>- <b>218 Trainingsläufe</b></li> <li>- <b>Nicht direkt ersichtlich</b></li> </ul> 5.3 Datenqualität <ul style="list-style-type: none"> <li>- <b>Normalverteiltes Rauschen</b></li> </ul>	6.1 Ursprung <ul style="list-style-type: none"> <li>- <b>Simulation</b></li> </ul>

Bei diesem Datensatz handelt es sich um ein gut dokumentiertes und beschriebenes Beispiel [29]. Dennoch gibt es bei Teilen der Kriterien nicht triviale Einordnungen, welche bei weiteren, weniger detaillierten und beschriebenen Datensätzen aus der Übersicht in Tabelle 2, ansteigen. Dies liegt einerseits daran, dass keine oder nicht ausreichende Informationen bzgl. der Kriterien vorliegen und andererseits an mehrdeutigen Einordnungsmöglichkeiten.

Bei dem oben aufgeführten Beispiel liegen keine oder nicht ausreichende Informationen bei den Unterkriterien 4.3 und 4.4 vor, weshalb nur Annahmen anhand der Interpretation der Systembeschreibung getroffen werden können. Mehrdeutige Einordnungsmöglichkeiten liegen bei den Unterkriterien 1.1 und 2.1 vor. Die Beschreibung des Datensatzes in [29] lässt bzgl. dem Unterkriterium 1.1 zwei Einordnungen zu. Als Ende der Daten wird eine Grenze beschrieben, über die hinaus das System nicht betrieben werden darf. Dies entspricht einerseits einem Schwellwert (threshold) oder andererseits einem Systemausfall (failure). Beim Unterkriterium 2.1 ist eine Einordnung als kontinuierliche oder periodische Aufzeichnung

möglich, da die Daten in jedem Betriebszyklus aufgezeichnet werden, diese wiederum aber nur Momentaufnahmen innerhalb des Betriebszyklus darstellen. Da in dem betrachteten Beispiel die verbleibenden Betriebszyklen der RUL entsprechen, kann eine kontinuierliche Aufzeichnung zugeordnet werden. Ein Betriebszyklus entspricht allerdings einer relevanten Dauer innerhalb der Lebensdauer, weshalb eine periodische Aufzeichnung ebenfalls zugeordnet werden kann.

Bei der Weiterentwicklung des Lösungskonzeptes gilt es die notwendigen Annahmen und Mehrdeutigkeiten zu beachten und Abhilfemaßnahmen zu erarbeiten. Ebenfalls kann anhand des Beispiels die Relevanz der Kriterien und deren Ausprägungen gezeigt werden.

## 6 Ausblick

Um eine praxisrelevante Auswahlmethodik für Prognoseverfahren zu erhalten, wird die Vorgehensweise zur Definition von Standardfällen in diesem Beitrag erläutert. Für die weitere Erarbeitung der Auswahlmethodik gilt es mögliche Prognoseverfahren den relevanten Codierungen eines Standardfalls, also der entsprechenden Datencharakteristik, zuzuordnen. Daraus kann eine praxisrelevante Auswahlmethodik abgeleitet werden. Dazu ist die Reduktion der kombinatorisch möglichen Codierungen auf eine praxisrelevante Anzahl durchzuführen. Unter anderem gilt es für die nicht binären Kriterien Wertebereiche zu definieren, um eindeutige Zuordnungen zu ermöglichen. Das daraus resultierende Bewertungsschema kann darüber hinaus zur Charakterisierung der frei zugänglichen Datensätze verwendet werden und die beim Anwendungsbeispiel beschriebenen Annahmen und Mehrdeutigkeiten bei der Einordnung der Kriterien beheben. Dadurch können vergleichbare Datencharakteristika gefunden und passende Prognoseverfahren ausgewählt werden.

Bereits aus dem zuvor beschriebenen Beispiel wird ersichtlich, dass die frei zugänglichen Daten nicht alle Kriterien der Standardfälle erfüllen oder Informationen dazu fehlen. Die vorhandenen Datensätze erleichtern den Einstieg in die PHM-Verfahren und fördern den Kompetenzaufbau. Zusätzliche und vor allem praxisrelevante Datensätze gilt es in der Zukunft stetig zu publizieren, um die industrielle Verbreitung von PHM bzw. PdM nachhaltig zu fördern.

## Danksagung

Dieser Beitrag ist im Rahmen des Forschungsprojekts „Prognostics“ entstanden. Das Forschungsprojekt ist Bestandteil der „Förderung von FuE-Projekten an Hochschulen für angewandte Wissenschaften (HAW) durch das Land Baden-Württemberg (Ministerium für Wissenschaft, Forschung und Kunst) – Innovative Projekte 2019“. Der Dank der Autoren gilt dem Fördergeber.

## Literaturangaben

- [1] Cachada, A., Moreira, P. M., Romero, L., Barbosa, J., Leitno, P., Gcraldcos, C. A., Deusdado, L., Costa, J., Teixeira, C., Teixeira, J. u. Moreira, A. H.: Maintenance 4.0: Intelligent and Predictive Maintenance System Architecture. Proceedings 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA). Politecnico di Torino, Torino, Italy, 04-07 September 2018. Piscataway, NJ: IEEE 2018, S. 139–146
- [2] Yan, J., Meng, Y., Lu, L. u. Li, L.: Industrial Big Data in an Industry 4.0 Environment: Challenges, Schemes, and Applications for Predictive Maintenance. IEEE Access 5 (2017), S. 23484–23491
- [3] Zonta, T., da Costa, C. A., da Rosa Righi, R., Lima, M. J. de, da Trindade, E. S. u. Li, G. P.: Predictive maintenance in the Industry 4.0: A systematic literature review. Computers & Industrial Engineering 150 (2020), S. 106889
- [4] Kim, N.-H., An, D. u. Choi, J.-H.: Prognostics and Health Management of Engineering Systems. Cham: Springer International Publishing 2017
- [5] Hou-bo, H., Jian-min, Z. u. Chang-an, X.: Cost-benefit Model for PHM. Procedia Environmental Sciences 10 (2011), S. 759–764
- [6] Pecht, M. G. u. Kang, M.: Prognostics and Health Management of Electronics. Fundamentals, Machine Learning, and Internet of Things. Wiley - IEEE Ser. Newark: John Wiley & Sons Incorporated 2018
- [7] BearingPoint: Wie weit ist Ihr Unternehmen bei dem Thema "Predictive Maintenance" fortgeschritten?, 2017.  
<https://de.statista.com/statistik/daten/studie/801044/umfrage/umsetzung-von-predictive-maintenance-im-dach-gebiet/>, abgerufen am: 18.01.2021
- [8] Lei, Y., Li, N., Guo, L., Li, N., Yan, T. u. Lin, J.: Machinery health prognostics: A systematic review from data acquisition to RUL prediction. Mechanical Systems and Signal Processing 104 (2018), S. 799–834
- [9] Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L. u. Siegel, D.: Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. Mechanical Systems and Signal Processing 42 (2014) 1-2, S. 314–334
- [10] Tsui, K. L., Chen, N., Zhou, Q., Hai, Y. u. Wang, W.: Prognostics and Health Management: A Review on Data Driven Approaches. Mathematical Problems in Engineering 2015 (2015), S. 1–17
- [11] Aizpurua Unanue, J. u. Catterson, V. M.: Towards a methodology for design of prognostics systems. PHM 2015. Proceedings of the Annual Conference of the Prognostics and Health Management Society 2015 ; San Diego, CA, USA, October 18 - 22, 2015. San Diego 2015, S. 196–209
- [12] Ochella, S. u. Shafiee, M.: Artificial Intelligence in Prognostic Maintenance. Proceedings of the 29th European Safety and Reliability Conference (ESREL). 22-26 September

- 2019, Hannover, Germany. [Europe], Singapore: European Safety and Reliability Association; Research Publishing Services 2019, S. 3424–3431
- [13] Si, X.-S., Wang, W., Hu, C.-H. u. Zhou, D.-H.: Remaining useful life estimation – A review on the statistical data driven approaches. *European Journal of Operational Research* 213 (2011) 1, S. 1–14
- [14] Ooijevaar, T., Pichler, K., Di, Y. u. Hesch, C.: A Comparison of Vibration based Bearing Fault Diagnostic Methods. *International Journal of Prognostics and Health Management* 10 (2019)
- [15] Bertsche, B. u. Lechner, G.: Zuverlässigkeit im Fahrzeug- und Maschinenbau. Ermittlung von Bauteil- und System-Zuverlässigkeiten. VDI-Buch. Berlin: Springer Berlin 2004
- [16] PHM Society: PHM Society, 2021. <https://www.phmsociety.org/>, abgerufen am: 14.01.2021
- [17] NASA Official: Sonie Lau: Prognostics Center of Excellence - Data Repository, 2021. <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>, abgerufen am: 15.02.2021
- [18] Fraunhofer-Institut für Produktionstechnologie IPT: Machine Learning - IPT, 2021. <https://www.ipt.fraunhofer.de/de/kompetenzen/ProduktionsqualitaetundMesstechnik/produktionsqualitaet/machine-learning.html>, abgerufen am: 21.01.2021
- [19] Kaggle: Your Home for Data Science, 2021. <https://www.kaggle.com/>, abgerufen am: 25.01.2021
- [20] UCI Machine Learning Repository, 2021. <https://archive.ics.uci.edu/ml/index.php>, abgerufen am: 25.01.2021
- [21] Zenodo - Research. Shared, 2021. <https://zenodo.org/>, abgerufen am: 25.01.2021
- [22] OpenML, 2021. <https://www.openml.org/>, abgerufen am: 25.01.2021
- [23] Welcome - OpenEI Datasets, 2021. <https://openei.org/datasets/>, abgerufen am: 25.01.2021
- [24] Mendeley Data, 2021. <https://data.mendeley.com/>, abgerufen am: 09.02.2021
- [25] GitHub: GitHub: Where the world builds software, 2021. <https://github.com/>, abgerufen am: 25.01.2021
- [26] OpenAI: OpenAI. <https://openai.com/>, abgerufen am: 25.01.2021
- [27] GitHub: PHM-Hochschule-Esslingen/Degradationsdaten\_TTZ\_2021, 2021. [https://github.com/PHM-Hochschule-Esslingen/Degradationsdaten\\_TTZ\\_2021](https://github.com/PHM-Hochschule-Esslingen/Degradationsdaten_TTZ_2021), abgerufen am: 12.02.2021
- [28] NASA Official: Sonie Lau: PHM Data Challenge 2008: Prognostics Center of Excellence - Data Repository, 2021. [https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#phm08\\_challenge](https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#phm08_challenge), abgerufen am: 04.02.2021
- [29] Saxena, A., Goebel, K., Simon, D. u. Eklund, N.: Damage propagation modeling for aircraft engine run-to-failure simulation. 2008 International Conference on Prognostics and Health Management. (PHM) ; Denver, Colorado, USA, 6 - 9 October 2008. Piscataway, NJ: IEEE 2008, S. 1–9





# Methodik zur Schadensquantifizierung in hydraulischen Axialkolbeneinheiten unter variablen Betriebsbedingungen

M.Sc. **Hannes Hitzer**, Bosch-Rexroth AG, Horb am Neckar;

Dr.-Ing. **Daniel Hast**, Bosch-Rexroth AG, Schwieberdingen;

Prof. Dr.-Ing. **Stefan Böttinger**, Universität Hohenheim, Stuttgart

## Kurzfassung

Dieser Beitrag stellt eine Methodik zur Quantifizierung des Schadenszustandes in hydrostatischen Verdrängereinheiten vor, welche variablen Betriebslastbedingungen ausgesetzt sind. Die Methodik kann angewandt werden, wenn der Schadenszustand in den Untersuchungsobjekten nicht direkt beobachtbar ist, jedoch Schadenszustände aus weiteren, vergleichbaren Einheiten vorliegen. Neben dem Erlernen des funktionalen Zusammenhangs zwischen Schadensindikatoren und Betriebslastgrößen auf die Schadensausprägung erweitert der Beitrag bisherige Ansätze zur Schadensquantifizierung um die Darstellung der Vorhersageunsicherheit durch Wahrscheinlichkeitsverteilungen. Anhand eines Fehlerfalls und unter Verwendung von Prüfstanddaten werden die Anwendung der Methodik validiert und die Ergebnisse vorgestellt.

## 1. Motivation und Einordnung

Die Popularität des Forschungsfeldes Fehlererkennung und Schadensdiagnose von Maschinenelementen wächst seit Jahren kontinuierlich [1]. Mit stetig zunehmender Verfügbarkeit an Daten durch voranschreitende Digitalisierung und steigendem Bedarf an Condition-Monitoring Ansätzen wächst auch der Einsatz datengetriebener Methodik. Während sich bis vor wenigen Jahren die Ansätze hauptsächlich auf Komponentenebene wie Wälzlager bezogen [2], verlagern sie sich heutzutage in Richtung von Betrachtungen auf Systemebene. In [3] wird dazu ein Autoencoder-Ansatz zur Anomalieerkennung in Gasturbinen vorgestellt, während in [4] Schäden in Getrieben detektiert werden. Das Erkennen und Isolieren von Fehlern im Betrieb ist bei der Validierung maßgeblich für eine erfolgreiche vorausschauende Wartungsstrategie. Um relevante Entscheidungen aus der Fehlererkennung ableiten zu können, müssen so viele Informationen wie möglich aus dem Verhalten der Maschine unter Einfluss eines erkannten Fehlers extrahiert werden. Dazu gehört insbesondere zu erkennen, ob sich der Fehler in einem frühen Stadium befindet, d.h. ob noch ausreichend Abnutzungsvorrat bis zum Ausfall der Maschine vorhanden ist, oder ob ein unplanmäßiger Stillstand unmittelbar bevorsteht. Für nachfolgende Entscheidungen, wie eine Änderung des Nutzungsprofils der Anwendung oder das

Auslösen logistischer Lieferprozesse, z.B. zur Ersatzteilbeschaffung, ist eine Schadensbeurteilung und –quantifizierung daher zusätzlich zur Erkennung eines Fehlers immanent wichtig. Da der Schadenszustand in vielen Maschinen häufig nicht im laufenden Betrieb beobachtet werden kann, müssen ersatzweise Indikatorgrößen gefunden werden anhand derer der Schadenszustand möglichst präzise geschätzt werden kann.

Um die Relevanz einer solchen Schätzung zu unterstreichen und Schnittstellen der Schadensquantifizierung aufzuzeigen, ist eine Sicht auf den operativen Prozess Prognostics and Health Management (PHM) notwendig. Nach [5] besteht ein PHM-Prozess aus fünf Schritten (Sense, Acquire, Analyze, Advise und Act). In unserem Beitrag beziehen wir uns auf den Aspekt der Schadensquantifizierung (Assessment), welcher Teil des Schrittes Analyze ist. Vor der Schadensquantifizierung erfolgt im Prozess eine Fehlererkennung und Fehleridentifikation, nach der Schadensquantifizierung die zeitliche Extrapolation des Schadensverlaufs zur Ermittlung der wahrscheinlich nutzbaren Restlebensdauer. Da viele Ansätze in der Literatur zwar die Fehlererkennung und Fehlerdiagnose thematisieren, die nachfolgende Prognose jedoch weitestgehend außer Acht lassen, zielt dieser Beitrag darauf ab diese Lücke zu schließen. Dabei sind die Schätzung und Quantifizierung des aktuellen Schadenszustandes sowie die Kenntnis über die damit verbundene Unsicherheit von zentraler Bedeutung.

Auf abstrakter Ebene lässt sich das Problem der Schadensquantifizierung als Regressionsproblem formulieren. Als unabhängige Variablen, d.h. als Eingangsdaten, dienen dabei Schadensindikatoren und Betriebslastgrößen, mit denen durch ein Modell eine Bild auf den Schadenszustand (abhängige Variable) erfolgt. Prinzipiell lässt sich diese Problemstellung auf eine Vielzahl technischer Systeme übertragen, wir demonstrieren hier eine Methodik zur konkreten Anwendung an einer hydraulischen Axialkolbenpumpe. Ihr Einsatzgebiet erstreckt sich von stationären Anwendungen (z.B. Umformpressen) bis zu mobilen Anwendungen (z.B. Land- und Baumaschinen). Das Schadensmaß kann im vorliegenden Fall nicht ohne aufwändige Demontage und Vermessung der Pumpeneinheit direkt gemessen werden. Auch aus Sicht der Modellierung kommt zur bisher beschriebenen Thematik ein weiteres Kernproblem. Parametrische Regressionsverfahren setzen vorab eine Zielfunktion voraus, um die Parameter z.B. durch die Minimierung der Fehlerquadrate auf die Daten hin zu optimieren. Nachteile eines solchen Ansatzes sind erstens, dass der funktionale Zusammenhang zwischen Schadensindikator und Schadensausmaß bereits qualitativ bekannt sein muss. Zweitens werden bei der Methode der kleinsten Quadrate die Fehlerterme als mittelwertfrei und mit konstanter Varianz angenommen (Homoskedastizität). In der praktischen Anwendung kann sich die Varianz der Fehlerterme jedoch ändern (Heteroskedastizität), sodass hier eine wichtige Annahme verletzt

wird und damit eine Schätzung suboptimal sein wird. Ein Modell, welches neben dem Schadensmaß auch die Unsicherheit schätzt, muss folglich die Möglichkeit haben, diese systembedingte Änderung miteinzubeziehen. Die Vorhersage einer Wahrscheinlichkeitsverteilung des aktuellen Zustands unter den erwähnten Nebenbedingungen ergibt sich also als ein Ziel der zu entwickelnden Methodik.

## 2. Unsicherheitsschätzung in PHM-Systemen

Dieses Kapitel gibt einen Überblick über die Kategorisierung und Identifikation von Unsicherheit in Vorhersagen. Wir definieren, welche Art von Unsicherheiten die vorgestellte Methodik berücksichtigt und wie diese quantifiziert werden. Ein Ansatz ist zwischen aleatorischer Unsicherheit (entsteht durch physikalische Variabilität und Zufallsprozesse) und epistemischer Unsicherheit (Mangel an besserem Wissen) zu unterscheiden [6]. Für Condition-Monitoring- und PHM-Anwendungen argumentiert dagegen [7], dass diese Einteilung der Unsicherheiten aufgrund des Fehlens der „wahren Variabilität“ in der Regel nicht möglich ist. Stattdessen schlägt [7] vor, die Unsicherheit in vier Unterkategorien einzuteilen. Diese Betrachtungsweise teilt auch [8], der die Kategorien leicht modifiziert aufgreift. Im vorliegenden Fall kategorisieren wir die Unsicherheit entsprechend [8] und erläutern diese in Bezug auf den Anwendungsfall der Hydraulik:

- Unsicherheit in Eingangsgrößen:
  - Wir nehmen an, dass die gemessenen (tatsächlichen) Einzelschadenszustände normalverteilt sind.
  - Wir untersuchen zwei Pumpen. Aus statistischer Sicht lässt sich damit nur eine eingeschränkte Aussage über die Gesamtheit aller Pumpen hinsichtlich der Repräsentativität der Daten (z.B. hinsichtlich Fertigungstoleranzen) erzielen.
  - Die Betriebsparameter können einen Einfluss auf die Schadensindikatoren haben. Bspw. kann eine bestimmte Drehzahl zu Resonanzen führen, sodass Schadensindikatoren nicht gleich repräsentativ sind wie bei anderen Drehzahlen. Wir nehmen an, dass diese Unsicherheit durch die Berücksichtigung des kompletten Betriebslastbereichs (statistisches Kennfeld, siehe auch Kapitel 3) in den Messungen enthalten ist.
  - Sich ändernde Bedingungen (z.B. Untergrund, klimatische Einflüsse), der Einfluss von Peripherieanbauten (z.B. Ventile, Dieselmotor, Schlauchlängen) sowie die Sensorbefestigung (Art der Befestigung und Sensorposition) sind eine weitere Quelle für mögliche Unsicherheit. Jene wird im Prüfstands Aufbau nicht berücksichtigt.

- Unsicherheit in Methodik und Modell: Eine ungeeignete Methodik oder ein ungeeignetes Modell können zu einer Über- oder Unteranpassung des Zusammenhangs Schadensindikatoren – Schadensausmaß führen. Diese Unsicherheit kann unter sonst gleichen Bedingungen durch den Fehlervergleich der Modelle zwischen Trainings- und Testdaten ermittelt werden.
- Unsicherheit in den Messungen der Betriebslastgrößen sowie Unsicherheit in der Messung der Schadensindikatoren: Die Unsicherheiten werden durch den Sensor und die Signalverarbeitungskette verursacht (Sensorauswahl und -genauigkeit, Langzeitdrift, Temperatureinfluss etc.). Wir gehen davon aus, dass diese Unsicherheit mittelwertfrei ist und einer Normalverteilung folgt.

Allgemein lässt sich Unsicherheit durch Wahrscheinlichkeitsverteilungen beschreiben. Im vorliegenden Fall wird angenommen, dass die Vorhersagen normalverteilt sind. Somit lassen sich die Verteilungen vollständig durch den Erwartungswert und die Varianz beschreiben.

### 3. Methodik und untersuchter Fehlerfall

Um eine Methodik zur Schadensquantifizierung zu entwickeln, treffen wir die Annahme, dass der vorliegende Schaden detektiert und klassifiziert werden kann. Diese Annahme stützt sich auf die Ergebnisse von [9-11], die für die Anwendung der Axialkolbeneinheit die Detektion und Diagnose des Schadenstyps „axiales Spiel“ zwischen Kolben und Gleitschuh zeigen. Außerdem belegen [9] die Feldrelevanz dieses Schadenstyps. Darauf aufbauend beschreiben wir das Problem der Schadensquantifizierung in der Form

$$S(x) = \sum_{i=0}^{n-1} \beta_i x_i + \epsilon. \quad (1)$$

$S$  beschreibt den Schaden in Abhängigkeit der Eingangsgrößen  $x_i = \{x_0, \dots, x_{n-1}\}$ , welche die Schadensindikatoren und Betriebslastgrößen darstellen, und  $\epsilon \sim N(0, \sigma_m^2)$  eine normalverteilte Rauschgröße. Das Regressionsproblem (1) unterliegt zwar der Annahme der Linearität in den Variablen, jedoch lassen sich die linearen Terme auch durch nichtlineare Terme ersetzen. Der Datensatz, welcher als Grundlage für die Untersuchung verwendet wird, ist am Testprüfstand erzeugt (Bild 1a). Dabei sind die Signale der physikalischen Größen, deren Charakteristik sich durch einen Schaden ändert, sowie die Signale der Betriebslastgrößen von zwei Pumpen in jeweils vier unterschiedlichen Schadenszuständen aufgezeichnet. Die Schadenszustände sind nach Bild 1c) ein Gutzustand, ein beginnender Schaden, ein fortgeschrittener Schaden sowie ein kritischer Schaden. Jeder Untersuchungslauf (eine Pumpe und ein Schadenszustand) besteht aus 80 verschiedenen stationären Messreihen. Die 80 Messreihen werden

durch ein statistisches Kennfeld (Design of Experiments) definiert, sodass der Raum über den Betriebsparametern Hochdruck  $p_{HD}$ , Drehzahl  $n$ , Schwenkwinkel  $\alpha$  und der Tank-Öltemperatur  $T_{Tank}$  innerhalb der Spezifikationen der Einheit (Rexroth A4VSO125) abgedeckt ist. Die Last im Versuchsaufbau wird durch ein schaltbares Ventil dargestellt. Der eingebrachte Fehler „axiales Spiel“ beschreibt eine Aufweitung der Umbördelung des Gleitschuhs (plastische Deformation), wodurch sich das Spiel zwischen der Bauteilpaarung Gleitschuh und Kolbenkopf vergrößert. Ursächlich ist dies auf Saugmangel zurückzuführen, wodurch das Kräftegleichgewicht zwischen Kolben und Gleitschuh gestört wird. Durch die Rotation des Triebwerks und die wechselnde Zug- und Druckbelastung vergrößert sich das Spiel im Betrieb kontinuierlich. Dies führt wiederum zu größeren Vibrationen in axialer Richtung, Zunahme der internen Leckage sowie einem verringerten Wirkungsgrad. Die detaillierte Entstehung dieses Fehlers ist in [9] im Detail beschrieben. Demnach sind die Oberflächenschwingbeschleunigung und der Gehäusedruck als Signale zur Bildung der Schadensindikatoren ausgewählt.

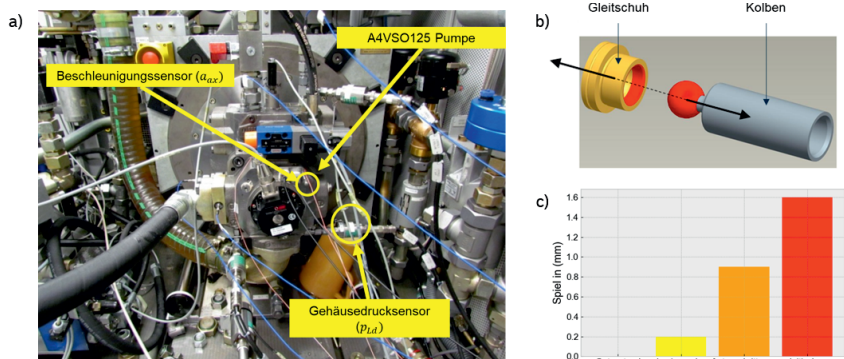


Bild 1: Datenerzeugung. a) Testaufbau mit Pumpe und Sensorik für die Ermittlung der Schadensindikatoren. b) Fehlerfall des axialen Spiels zwischen Kolben und Gleitschuh. c) Gemessene diskrete Schadenszustände

Eine Abtastrate von 50 kHz stellt sicher, dass auch Signaländerungen im hochfrequenten Bereich erfasst werden können. Im Folgenden wird nun die Methodik (siehe Bild 2) beschrieben, die zur Beurteilung des Schadenszustands verwendet wird. Die Erkennung des Fehlers wird dabei als Stand der Technik betrachtet und nicht weiter erläutert.

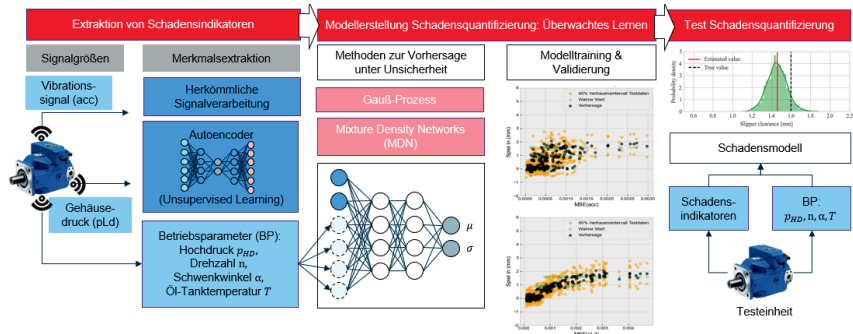


Bild 2: Kern der Methodik

### Merkmalsextraktion und Entwicklung schadenssensitiver Merkmale

Als Schadensindikatoren eignen sich Kennwerte aus den Signalen, die eine Information über den Schädigungszustand beinhalten (z.B. Korrelation oder Transinformation). Zudem muss auch eine Kausalität, d.h. eine Ursache-Wirkungs-Beziehung mit dem Schaden vorhanden sein, um falsche Schlussfolgerungen zu vermeiden. In diesem Beitrag werden zwei Herangehensweisen zur Merkmalsextraktion verfolgt: die Extraktion mittels Methoden der Signalverarbeitung (im Weiteren auch als SV-Merkmale bezeichnet) und die Extraktion mittels eines Autoencoders (AE-Merkmale). Für die SV-Merkmale wird die Python-Bibliothek *tsfresh* [12] zur Extraktion von ca. 1200 Signalmerkmalen verwendet, die den Zeit-, den Frequenz- und Zeitfrequenzbereich abdecken. Eine sehr große Anzahl an Merkmalen erhöht jedoch in den meisten Fällen die Modellkomplexität, was sich negativ auf die Generalisierung des Modells auswirkt. Um ungeeignete Merkmale vor dem Training des Modells herauszufiltern, werden die Merkmale daher zunächst über einen Pearson-Korrelationsfilter bewertet und selektiert. Die Auswahl beschränkt sich auf acht Schadensindikatoren.

Außerdem verwenden wir einen Ansatz zum selbstständigen Erlernen von Merkmalen mittels Autoencoder (sog. Deep Learning) indem alle Trainingspektren global auf den Wertebereich zwischen 0 und 1 normiert und durch eine kubische Wurzeltransformation in eine einheitliche Skalierung und Struktur gebracht werden. Diese Transformation dient dazu, die Gefahr einer antrainierten Tiefpassfilterung zu umgehen, da niedrige Frequenzen im Anwendungsfall Axialkolbeneinheit größere Amplituden aufweisen als hohe Frequenzen. Eine weitere Eigenschaft, die zum besseren Lernprozess beiträgt, ist die Überlagerung der Eingangsdaten mit normalverteiltem Rauschen im Trainingsprozess. Derart nimmt der Autoencoder eine

Rauschreduzierung vor und verhindert damit ein einfaches Kopieren der Spektren. Anschließend kann durch die Differenzbildung der Ausgangsspektren mit den Eingangsspektren festgestellt werden, ob sich die Struktur in den Daten geändert hat, also ein Schaden in der Einheit vorliegt oder nicht. Ein wesentlicher Vorteil dieses Ansatzes ist, dass sich damit die Dimension im Merkmalsraum direkt reduzieren lässt und mit den Ausgangsgrößen des Autoencoders unabhängig des Betriebspunkts eine Aussage über eine Fehlerdetektion möglich ist [10].

### **Gauß-Prozesse**

Im Gegensatz zu parametrischen Ansätzen wird bei Gauß Prozessen (GP) keine bestimmte Funktion vorgegeben, sondern die unbekannten Funktionswerte werden über eine Kernel-Funktion ermittelt. Die Kernelfunktion ordnet dabei einem unabhängigen Variablenvektor denjenigen Funktionswert zu, der eine hohe Ähnlichkeit zu bereits bekannten Funktionswerten aufweist. Eine ausführliche Erläuterung der Funktionsweise von GP sowie mathematische Hintergründe können in [13] nachgelesen werden. Die wichtigsten Vor- und Nachteile in der Anwendung sind in der Tabelle 1 zusammengefasst.

### **Mixture Density Networks**

Mixture Density Networks (MDN) sind ein spezieller Typ neuronaler Netze in Kombination mit Gauß'schen Mischmodellen, die neben der Vorhersage einer Ausgangsvariablen eine zugehörige Wahrscheinlichkeitsverteilung liefern. Erstmals vorgestellt von [14], erstreckt sich deren Anwendungsgebiet heutzutage auf zahlreiche Gebiete in denen bedingte Wahrscheinlichkeitsverteilungen eine Rolle spielen [15, 16].

Tabelle 1: Vor- und Nachteile der eingesetzten Regressionsmethodik

Gauß-Prozesse (GP)	
Vorteile	<ul style="list-style-type: none"> <li>• Flexibilität und Anpassungsfähigkeit, kein iterativer Trainingsprozess.</li> <li>• Automatischer Trade-Off zwischen Modellkomplexität und Anpassungsgüte [13].</li> <li>• Vorwissen kann in Form von möglichen Verteilungen über Funktionen und beliebig kombinierbaren Kernel-Funktionen integriert werden [13].</li> <li>• Gute Interpretierbarkeit und Kontrollierbarkeit der Modellkomplexität.</li> <li>• Modelle eignen sich auch für vergleichbar kleine Datensätze [17].</li> </ul>
Nachteile	<ul style="list-style-type: none"> <li>• Hoher Rechenaufwand bei vielen Stichproben und vielen Merkmalen.</li> <li>• Standard-GP beruht auf der Annahme der Homoskedastizität und normalverteilten Größen.</li> </ul>
Mixture Density Networks (MDN)	
Vorteile	<ul style="list-style-type: none"> <li>• Für hochdimensionale Daten gut geeignet.</li> <li>• Neuronale Netzarchitektur ist in der Lage beliebig komplexe Zusammenhänge zu fitten.</li> <li>• Kann nicht normalverteilte, multimodale Verteilungen approximieren.</li> </ul>
Nachteile	<ul style="list-style-type: none"> <li>• Erschwerte Interpretation und Erklärbarkeit des Modells.</li> <li>• Erfordert eine größere Menge an Trainingsdaten.</li> </ul>

#### 4. Vorgehen

Da die Schadensindikatoren und Betriebslastgrößen unterschiedliche Skalierungen aufweisen, werden die Eingangsgrößen in der Vorverarbeitung jeweils auf Mittelwertfreiheit und Standardabweichung 1 skaliert. Bild 3 zeigt beispielhaft vier der acht selektierten Merkmale aus der Signalverarbeitung in den unterschiedlichen Schadensausprägungen. Für das GP-Modell wird ein Squared Exponential Kernel verwendet. Gemäß [17] eignet sich dieser Kernel zur glatten Interpolation, wenn keine Periodizität in der Ausgangsgröße zu erwarten ist. Da monoton zu- bzw. abnehmende Funktionen in den Schädigungsmerkmalen zu erwarten sind, wird dieser Kernel zusätzlich um eine Mittelwertfunktion entsprechend der Merkmalsdimensionen als Vorwissen ergänzt. Dabei ist die Berücksichtigung der Heteroskedastizität (eingangsgrößenabhängige Varianz), welche die Annahme des Standard Gauß-Prozess Modells verletzt [18], herausfordernd. Heteroskedastizität kann in der Praxis graphisch über die Darstellung der Residuen oder über einen Breusch-Pagan-Test [19] nachgewiesen werden. Der hier verwendete Ansatz nach [20] beinhaltet ein GP-Modell mit latenter Variablen, sodass ein GP zur



Vorhersage des Funktionswertes ( $y$  – Prozess) und ein GP zur Vorhersage des Rauschniveaus ( $z$  – Prozess) implementiert ist. Die optimalen Hyperparameterwerte werden dabei über die Minimierung der negativen Log-Marginal-Likelihood-Funktion ermittelt. Das MDN-Netz besteht aus zwei Hidden-Layer Schichten à 20 Knoten. Die letzte Schicht besteht aus einem Knoten für den Erwartungswert und einem Knoten für die Standardabweichung. Das Training des Netzes erfolgt durch Optimierung der Gewichtungen und Verschiebungen mittels eines Gradientenwertverfahrens. Um lange Trainingszeiten und eine Überanpassung des Netzes zu verhindern, wird zusätzlich ein Early Stopping Kriterium und eine L2-Regularisierung pro Schicht implementiert. Early Stopping führt zu einem Abbruch des Trainingsprozesses, wenn die Änderungsrate der Verlustfunktion bei der Validierung eine Sättigung erreicht, d.h. das Netz nicht mehr weiter dazu lernt. Die L2-Regularisierung dient dagegen als zusätzliche Bedingung bei der Minimierung der Kostenfunktion, indem sie zu hohe Modellkomplexität bestraft. Anschaulich bedeutet dies, dass verhältnismäßig hohe Gewichtungen im Lernprozess bestraft werden, da diese im Modell zu sprunghaftem Verhalten, d.h. großen Änderungen in der Ausgangsgröße bei kleinen Änderungen in der Eingangsgröße führen können.

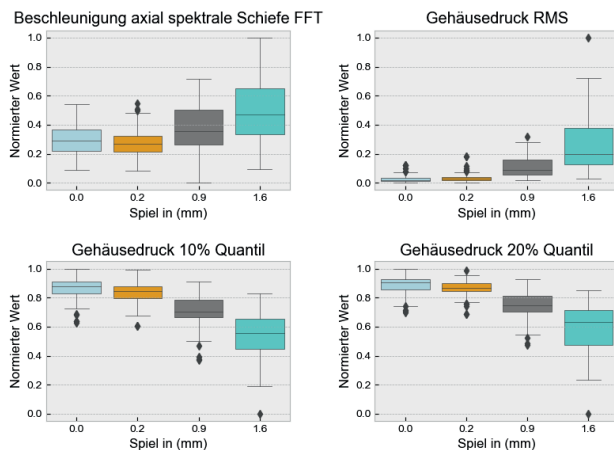


Bild 3: Selektierte Merkmale aus der Signalverarbeitung. Die Boxplots stellen den Median sowie das obere und untere Quartil dar. Ausreißer sind als Werte definiert, die einen höheren Wert als das obere/untere Quartil  $\pm 1.5$ -fachen des interquartilen Wertebereichs aufweisen. (Abkürzungen FFT: Fast-Fourier Transform, RMS: Root-Mean-Square)

## 5. Ergebnisse

Die beiden Methoden zur Ermittlung von Schadensindikatoren werden nun mit den beiden Methoden der Vorhersage unter Unsicherheit zusammengeführt, sodass sich in Summe vier Kombinationsmöglichkeiten ergeben. Diese werden anhand zweier Testszenarien beurteilt, wobei im *Testszenario 1* für jede der vier Kombinationsmöglichkeiten jeweils ein Vorhersagemodell anhand eines Teildatensatzes einer Pumpe (*Pumpe 1*) erstellt und auf einem anderen Teildatensatz derselben Pumpe sowie auf einem Datensatz einer weiteren, neuen Pumpe (*Pumpe 2*) evaluiert wird. Damit verfolgt dieses Testszenario das Ziel der Bewertung der Genauigkeit, der Präzision sowie der Übertragbarkeit der Modelle zwischen zwei Pumpen. *Testszenario 2* zielt dagegen auf die Bewertung und Quantifizierung des Einflusses der Eingangsgrößen auf die Unsicherheit in der Vorhersagegröße ab. Erreicht wird dies durch eine Sensitivitätsanalyse, welche den prozentualen Einfluss einer Eingangsvariable auf die Varianz in der Vorhersage des Spiels untersucht. Als Metriken werden der Root Mean Squared Error (RMSE) sowie der mittlere Fehler (Mean Error) eingesetzt. Erster stellt dabei ein Fehlermaß dar, welches die Standardabweichung der Residuen unabhängig des Vorzeichens evaluiert. Der mittlere Fehler dient zur Detektion einer systematischen Abweichung (Bias) im Modell.

Das *Testszenario 1*, bei dem zu jeder Merkmalsextraktionsmethode je ein GP- und ein MDN-Modell trainiert wird, liefert die Ergebnisse in Abhängigkeit des wahren Spiels, wie sie in Bild 4 dargestellt sind. Dabei fällt zunächst auf, dass bei der Evaluation über alle Trainings- und Testdaten hinweg der RMSE bei größeren Schädigungen zunimmt. Dies lässt sich einerseits auf die Heteroskedastizität in den Daten zurückführen, andererseits auf die Streuung und Ausreißer, die bei größerem Schaden zunehmen. Eine Betrachtung der prognostizierten Unsicherheit in Form der Standardabweichung untermauert diesen Rückschluss. Die Standardabweichung steigt von durchschnittlich 0.25 mm beim beginnenden Schaden auf durchschnittlich 0.33 mm beim kritischen Schaden (nicht in der Bild dargestellt). Anhand des mittleren Fehlers ist ersichtlich, dass im Gutzustand der Schaden leicht überschätzt und in der kritischen Schadensausprägung der Schaden leicht unterschätzt wird. Die Vermutung liegt nahe, dass dieser Umstand auf folgende Tatsache zurückzuführen ist. Da das Modell im Training keine größeren Spielwerte (Labels) als 1.6 mm erfährt, sorgt die große Streuung in der kritischen Schadensausprägung dafür, dass die Vorhersage ebenfalls gegen den Wert 1.6 mm strebt. Durch die Ergänzung weiterer Trainingsdaten mit mehr Schadensstufen jenseits der 1.6 mm, so die Vermutung, ließe sich dieser Effekt vermutlich beheben und der funktionale Zusammenhang zwischen Schadensindikator und Schadensausmaß wäre noch besser erlernbar. Da sich diese systematische Abweichung in allen Schadensstufen des Tests derselben Einheit jedoch im Rahmen  $\pm 0.2$  mm bewegt, können wir davon ausgehen ein hinreichend

gutes, d.h. im Sinne der pumpenspezifischen Generalisierbarkeit geeignetes Modell gefunden zu haben. Für die praxisnahe Interpretation verdeutlicht dieser Sachverhalt, dass Vorhersagewerten nahe oder jenseits der Grenze des Trainingswertebereichs nur im Rahmen der ausgewiesenen Fehlermaße zu vertrauen ist. Durch den Vergleich des Fehlermaß zwischen Testdaten derselben *Pumpe 1* und Testdaten einer neuen *Pumpe 2* kann exemplarisch aufgezeigt werden, wie groß der Einfluss bei der Stichprobenauswahl der Pumpen ist. Hier ergeben sich im Testfall der *Pumpe 2*, welche unter den gleichen Rahmenbedingungen eingesetzt wird, nur geringfügig höhere Fehlerwerte für den RMSE. Die zusätzliche systematische Abweichung, welche sich in den Ergebnissen der Testeinheit ausweisen lässt, ist demnach auf Fertigungs- und Montagetoleranzen zurückzuführen. Auch hier ist diese Quantifizierung jedoch im Kontext derselben Betriebsbedingungen und im gleichen Anwendungsszenarien zu betrachten, eine belastbare Quantifizierung der Unsicherheit bedingt durch externe Faktoren oder für die Gesamtheit aller Pumpen gleichen Typs ist aufgrund der geringen Stichprobenzahl nicht möglich. Für die Praxis kann damit dennoch die Hypothese bekräftigt werden, dass ein Modelltransfer zum Zweck der Schadensquantifizierung auf Pumpenexemplare gleicher Bauart und Größe, unter sonst gleichen Rahmenbedingungen und im gleichen Fehlerfall ohne Nachtrainieren des Modells möglich ist. Für den Fall, dass sich die Voraussetzungen ändern, so muss die Aussage überprüft und die Modelle ggf. neu trainiert oder nachtrainiert werden.

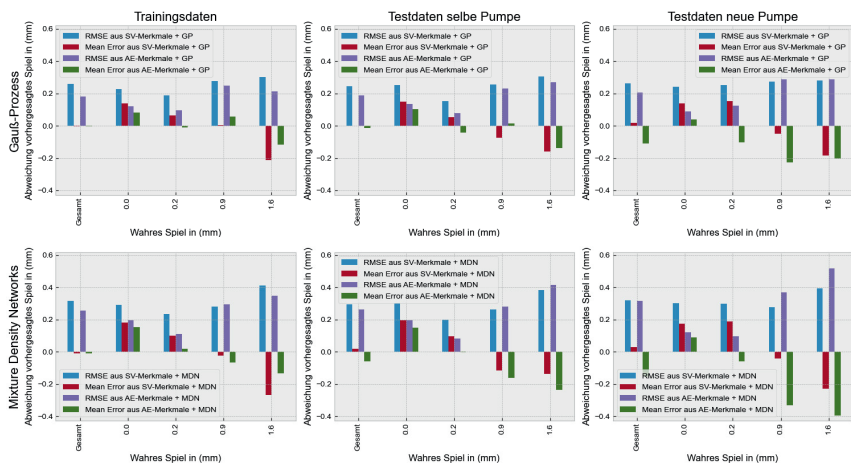


Bild 4: Evaluation der Methodik auf Trainings- und Testdaten. Dargestellt sind der RMSE und Mean Error aller vier Kombinationsmöglichkeiten (SV-Merkmale + GP, SV-Merkmale + MDN, AE-Merkmale + GP, AE-Merkmale + MDN).

Im Vergleich der beiden Ansätze GP und MDN lässt sich weiterhin festhalten, dass die Fehlermaße für GP durchschnittlich um 6% geringer ausfallen, sodass dieser Ansatz im vorliegenden (Fehler-)fall vorzuziehen ist. Zwischen den SV-Merkmalen und den AE-Merkmalen ist im Gesamten eine geringfügige Verbesserung der Vorhersagegenauigkeit durch die AE-Merkmale festzustellen. Ein direkter Vergleich des RMSE auf allen Testdaten zeigt hier eine Verbesserung von 2,1% des durchschnittlichen Fehlermaßes.

In *Testszenario 2* wird der Einfluss der einzelnen Schadensindikatoren durch eine Sobol-Analyse [21] für alle vier Merkmals- und Modellkombinationen untersucht. Zweck dieser Sensitivitätsanalyse ist die Quantifizierung der Unsicherheit, welche durch die Messung der Betriebsgrößen und Schadensindikatoren verursacht wird. Während in *Testszenario 1* die Unsicherheit durch die vorhergesagte Standardabweichung absolut quantifiziert wurde, steht bei der Sensitivitätsanalyse der relative Vergleich zwischen den Eingangsgrößen im Vordergrund. Ergänzt wird die Sensitivitätsanalyse durch eine systematische Reduktion der Trainingsdaten um einzelne Eingangsvariablen. Dies stellt einen praxisrelevanten Fall dar, da oft aus wirtschaftlichen oder bauraumbedingten Gründen nicht immer alle Betriebslastgrößen per Sensorik zu erfassen sind. Die Sensitivitätsanalyse ist weiterhin sinnvoll, um das Modellverhalten besser verstehen und nachvollziehen zu können und Änderungen in den erfassten physikalischen Größen zu interpretieren. Für die Praxis bedeutet dies außerdem, dass daraus gewonnene Informationen zur Auslegung des Datenerfassungssystems zurückgeführt werden können, um unter Umständen Einsparpotenzial in der Sensorik identifizieren zu können. Bild 5 zeigt den Einfluss auf die Varianz in der Ausgangsgröße in Bezug zu den Schadensindikatoren aus den SV-Merkmalen und die Betriebspunktgrößen in ihrem Verhältnis. Hier lässt sich die Varianz im Vorhersagewert zu 90% (GP-Prozess) und 78 % (MDN) aus den Schadensindikatoren erklären. Für die AE-Merkmale ergeben sich qualitativ ähnliche Darstellungen, jedoch ist der Einfluss der Betriebspunktgrößen mit im Schnitt nur 8,2 % etwas geringer (nicht in Bild 5 dargestellt). Weiterhin wird deutlich, dass die aus dem Gehäusedruck gewonnenen Merkmale (insbesondere der RMS) auf Schadensindikatorseite die Varianz im vorhergesagten Schadenswert am stärksten beeinflussen. Da der RMS ein Maß für den Energieinhalt des Signals ist, bedeutet dies für den vorliegenden Fehlerfall, dass bereits eine verhältnismäßig geringe Änderung des RMS, resultierend aus der zusätzlichen Volumenverdrängung des Öls im „Spielraum“ zwischen Kolben und Gleitschuh, eine große Streuung in der Vorhersage verursacht. Gestützt wird die Aussage des geringen Einflusses der Betriebslastinformationen auf die Schätzung des Schadens durch die zweite Auswertung in *Testszenario 2*, der Reduktion der Trainingsdaten um einzelne Sensorinformationen.




Bild 5: Normierter Einfluss auf die Varianz des vorhergesagten Spiels (Sensitivitätsanalyse nach [21]). Dargestellt sind die Effekte erster Ordnung.

In Bild 6 ist dazu die Evaluation des Modells auf den Testdaten der neuen Einheit (*Pumpe 2*) dargestellt. Dabei werden von links nach rechts gezielt einzelne Betriebslastgrößen eliminiert, sodass das Modell ohne diese Informationen den funktionalen Zusammenhang erlernen muss.

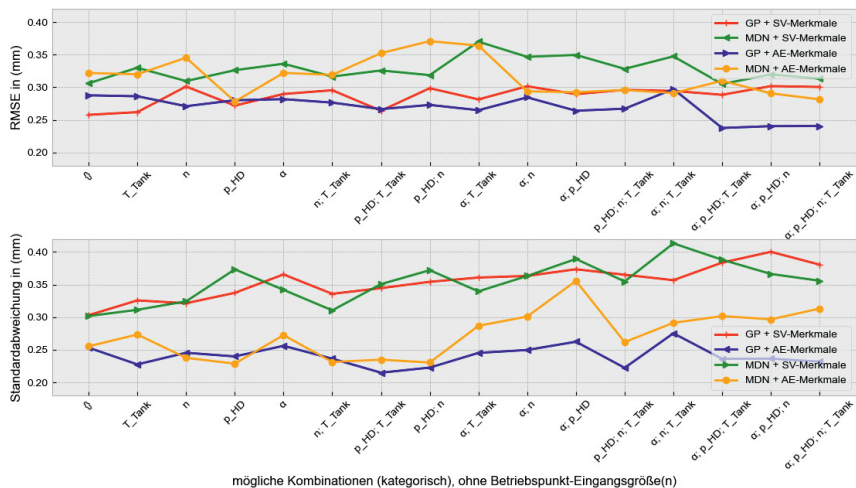


Bild 6: Oben: RMSE in Abhängigkeit möglicher Kombinationen der Einflussgrößen; Unten: Standardabweichungen in der Vorhersage in Abhängigkeit möglicher Kombinationen der Einflussgrößen

Es lässt sich in der oberen Bild erkennen, dass der Betriebspunkt die durchschnittliche Genauigkeit (RMSE) in der Schadensquantifizierung nicht signifikant beeinflusst. Betrachtet man dagegen die Vorhersagepräzision in Form der vorhergesagten Standardabweichung in der unteren Bild, lässt sich für die beiden Ansätze, die die Merkmale aus der Signalverarbeitung

verwenden, ein leichter Anstieg der Unsicherheit von 34% (GP + SV-Merkmale) und 25% (SV-Merkmale + MDN) zwischen „alle Betriebslastinformationen vorhanden“ und „keine Betriebslastinformationen vorhanden“ beziffern. Für die AE-Merkmale, welche durch die Vorverarbeitung der Daten bereits weitestgehend betriebspunktunabhängig sind, ist die Vorhersage dagegen präziser. Hier ist zu beobachten, dass die vorhergesagte Standardabweichung im Schnitt ca. 0.1mm geringer ausfällt. Insgesamt können wir damit festhalten, dass Gauß-Prozesse in Kombination mit AE-Merkmalen aufgrund der besseren Nachvollziehbarkeit des Lernprozesses und durch die hier ermittelten besseren Ergebnisse einen Vorteil gegenüber MDN bieten.

## 6. Zusammenfassung und Ausblick

Der Beitrag zeigt Möglichkeiten mit wahrscheinlichkeitstheoretischen Ansätzen die Unsicherheit in Vorhersagen zu quantifizieren. Am Beispiel des Fehlerfalls axiales Spiel zwischen Kolben und Gleitschuh in Hydraulikpumpen wurde die Anwendbarkeit von Gauß-Prozessen und Mixture Density Networks in technischen Systemen validiert. Die Ergebnisse zeigen, dass im vorliegenden Beispiel ein Modellübertrag auf eine weitere Einheit ohne Nachtrainieren des Modells möglich ist. Nichtsdestotrotz eignet sich der Gauß-Prozess als Ansatz aufgrund seiner Eigenschaften und der Einbettung in ein probabilistisches Framework auch für den Fall, Vorwissen in Form von Funktionen und Wahrscheinlichkeitsverteilungen in neue Modelle zu integrieren. Diese Einbettung kann beispielsweise für zukünftige Anwendungen derart verwendet werden, dass die an einer Einheit erlernte Posterior-Verteilung des funktionalen Zusammenhangs von Schadensindikatoren und Schaden als Prior-Verteilung für weitere Einheiten verwendet wird, welche dann mittels weniger neuer Messungen aktualisiert wird. Außerdem eröffnet er in Kombination mit weiteren stochastischen Verfahren, wie z.B. Monte-Carlo Simulationen, die Möglichkeit auch Unsicherheiten in einzelnen Modellparametern zu bestimmen. Notwendigerweise werden dazu im Trainingsprozess zwar Schadensmessungen benötigt, hypothetisch kann jedoch auch eine geeignete Schadenssimulation oder ein Vortrainieren auf Prüfstanddaten erfolgen. Dabei ist zu erwarten, dass die Robustheit als auch die Generalisierbarkeit zunimmt, je größer und breiter die Datenbasis für den betrachteten Fehlerfall wird. Der Übertrag der Methodik vom Prüfstand auf eine Feldanwendung bleibt dabei zentraler Forschungsgegenstand.

## Literatur

- [1] Gouriveau, R.; Zerhouni, N.; Medjaher, K.: From Prognostics and Health Systems Management to Predictive Maintenance – Monitoring and Prognostics. Wiley 2016.
- [2] Liao, L.; Wang, H.; Lee, J.: Bearing Health Assessment and fault diagnosis using the methods of Fast Fourier Transform and Self-Organizing Maps. Proceedings of 61<sup>st</sup> Meeting of the Society for Machinery Failure Prevention Technology. 2007
- [3] Yan, W.; Yun, L.: On Accurate and Reliable Anomaly Detection for Gas Turbine Com-bustors: A Deep Learning Approach. Annual Conference of the Prognostics and Health Management Society. 2015.
- [4] Li, X., Li, J., Qu, Y., He, D.: Semi-supervised Gear Fault Diagnosis Using Raw Vibration Signal Based on Deep Learning. Chinese Journal of Aeronautics 33. 2020
- [5] IEEE 1856-2017 Standard Framework for Prognostics and Health Management of Electronic Systems. IEEE Reliability Society 2017.
- [6] Knetsch, T.: Unsicherheiten in Ingenieurberechnungen. Otto-von-Guericke-Universität Magdeburg Diss. 2004.
- [7] Sankararaman, S.: Significance, interpretation, and quantification of uncertainty in prognostics and remaining useful life prediction. Mechanical Systems and Signal Processing. (2014) S. 228 – 247.
- [8] Corbetta, M.: Introduction to Prognostics. Annual Conference of the PHM Society 2019.
- [9] Du, J.; Wang, S.; Zhang, H.: Layered clustering multi-fault diagnosis for hydraulic piston pump. Mechanical Systems and Signal Processing. 2013.
- [10] Hitzer, H., Hast, D., Böttinger, S.: A Denoising Autoencoder methodology for fault detection in hydraulic axial piston pumps under variable operating conditions. Eingereicht für International Journal of Prognostics and Health Management. 2021.
- [11] Bayer, C., Enge-Rosenblatt, O.: Modeling of hydraulic axial piston pumps including specific signs of wear and tear. 8<sup>th</sup> International Modelica Conference, Dresden. 2011.
- [12] Christ, M.; Braun, N.; Neuffer, J.: Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – a Python package). Neurocomputing. 2018
- [13] Rasmussen, C.E: Gaussian Process in Machine Learning. Advanced Lectures on Machine Learning. Springer Verlag. 2004.
- [14] Bishop, C. M.: Mixture Density Networks. Neural Computing Research Group Report NCRG/94/004. Aston University Birmingham. 1994.
- [15] Davis, C. N. Hollingsworth, T. D., Caudron, Q., Irvine, M. A.: The use of mixture density networks in the emulation of complex epidemiological individual-based models. PLoS Comput Biol 16(3). 2020.

- [16] Capes, T.: Siri On-Device Deep Learning-Guided Unit Selection Text-to-Speech System. Interspeech 2017.
- [17] Duvenaud, D.: The Kernel Cookbook: Advice on Covariance functions. 2014.
- [18] Wang, C.: Gaussian Process Regression with Heteroscedastic Residuals and Fast MCMC Methods. University of Toronto Diss. 2014.
- [19] Breusch, T.S., Pagan, A.R.: A Simple test for heteroscedasticity and random coefficient variation. Journal of the Econometric Society, Econometria. 1979. S. 1287 – 1294.
- [20] Goldberg, P., Williams, C., Bishop, C.: Regression with Input-dependent Noise: A Gaussian Process Treatment. Advances in Neural Information Processing Systems 10. 1998.
- [21] Sobol, J.M.: Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates. Mathematics and Computers in Simulation 55. S. 271-280. 2001.



# Innovative Konzepte zur Zuverlässigkeitsbetrachtung von Hardware- und Software-Komponenten von Beatmungsgeräten

## Entwicklungsbegleitende Maßnahmen zur Zuverlässigkeitsabsicherung einer neuen Ventilator-Generation

Dipl.-Ing. **Martin Meyer**, Drägerwerk AG & Co. KGaA, Lübeck;  
Dr. rer. nat. **Jürgen Nuffer**, Dipl.-Ing. **Thomas Pfeiffer**,  
Dr.-Ing. **Matthias Rauschenbach**, B.-Eng. **Johannes Holz**,  
Gruppe Zuverlässigkeit und Sicherheit aktiver Systeme,  
Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF,  
Darmstadt

### Kurzfassung

Beatmungsgeräte stehen im Zuge der COVID 19-Pandemie aktuell im besonderen Fokus der öffentlichen Wahrnehmung. Die sichere und zuverlässige Funktion dieser Systeme war seit jeher eine zentrale Aufgabe der Hersteller. In einem gemeinsamen Projekt zwischen Dräger und Fraunhofer LBF wurden Konzepte entwickelt, um Beatmungsgeräte bzgl. Zuverlässigkeit zu bewerten. In diesem Vortrag werden zunächst spezifische Anforderungen an diese Systeme im Gesamtlebenszyklus vorgestellt.

Darauf aufbauend wurde eine Vorgehensweise entwickelt, um experimentelle und qualitative Methoden geeignet einzusetzen. Zur experimentellen Untersuchung wurden entsprechende Missionsprofile einzelner Subsysteme erstellt. Besondere Beachtung fand ein neu entwickeltes Kontrolldisplay, um die Bedienfunktionen hinsichtlich zeitlicher Entwicklung ihrer zuverlässigkeitsrelevanten Eigenschaften zu bewerten. Hierzu wurden für Einzelfunktionen spezifische Teststände und ein zugehöriges Testverfahren entwickelt.

Parallel dazu wurde bei Dräger eine neuartige Methode zur Bewertung der Software-Stabilität erarbeitet, deren Vorstellung den zweiten Teil des Vortrags ausmachen wird. Im Rahmen dieser Methode wird das System randomisierten sowie Skript-basierten Lastprofilen ausgesetzt, um SW-Fehlerzustände zunächst symptomatisch aufzudecken und anschließend die Wirkungsketten bis zur Ursache analytisch zu identifizieren und zu beheben.

## 1. Beatmungsgeräte – Anforderungen und Architektur

### 1.1. Einsatzprofil und Funktionsumfang von Beatmungsgeräten

Ein Beatmungsgerät (auch Respirator, engl. Ventilator) dient zur kontrollierten künstlichen Beatmung von Patienten, deren Eigenatmung (Spontanatmung) durch Unfall oder Erkrankung eingeschränkt oder ganz ausgesetzt ist. Durch die Beatmung wird der lebensnotwendige Gasaustausch in der Lunge des Patienten aufrechterhalten, bei dem das Blut mit Sauerstoff angereichert sowie CO<sub>2</sub> als Stoffwechselprodukt abgeführt wird.

Moderne Intensivbeatmungsgeräte ermöglichen unterschiedliche Beatmungsformen – z.B. druckkontrollierte und volumenkontrollierte Beatmung – sowie differenzierte Einstellmöglichkeiten von Atemfrequenz, Atemwegsdruck, Inspirations- zu Expirations-Verhältnis, Sauerstoffkonzentration und vieler weiterer Parameter. Daneben ist häufig ein Beatmungsmonitoring zur Vermeidung von Patientengefährdung integriert mit Überwachungs- und Sicherheitsfunktionen für Beatmungsdruck, Gaskonzentration, Temperatur, Feuchte etc.. Für die Beatmung von Neugeborenen und Säuglingen werden spezielle Gerätevarianten eingesetzt, die u.a. erhöhte Anforderungen bzgl. Druck- und Volumenregelung erfüllen.

Bild 1: Beatmungsgerät in der Anwendung auf der Intensivstation




Im klinischen Umfeld sind die Geräte im intensivmedizinischen Einsatz üblicherweise moderaten Umgebungsbedingungen ausgesetzt (Temperatur ca. 10°C – 40°C, Luftdruck 700 hPa – 1100 hPa, Feuchte 10% rH - 90% rH), werden aber häufig im 24/7-Einsatz - mitunter über mehrere Wochen bis einige Monate – betrieben; die jährliche Betriebsdauer beträgt nicht selten mehr als 5000 Stunden. Zum typischen Einsatzprofil gehört neben dem stationären Betrieb

auch der innerklinische Transport beatmeter Patienten, z.B. von der Notaufnahme in die Intensivstation, von dort zur Diagnostik usw.

### 1.2. Aufbau der Dräger-Beatmungsgeräte V-Family ‚Classic‘

Die Geräte der V-Familie ‚Classic‘ (Evita® V500, Evita® V300, Babylog® VN500) waren die ersten Dräger Beatmungsgeräte, die auf einer ab dem Jahr 2000 entwickelten Plattform-Architektur basieren. Die Grundstruktur beinhaltet die Ventilationseinheit (‚V-Box‘), in der ein Mikrocontroller-Board mit einem Echtzeit-Betriebssystem die Beatmungssteuerung- und Überwachung regelt, und eine Bedieneinheit (‚Cockpit‘), auf der ein Windows-basiertes Interface die Anzeige und Einstellung über Hard- und Softkeys (Touchscreen) sowie die optische und akustische Alarmierung übernimmt.

Bild 2: Beatmungsgerät Dräger Evita V500



### 1.3. Änderungsprojekt Dräger V-Family ‚ECD‘

Veranlasst durch die Ankündigung der Produktionseinstellung der verwendeten Touch-Displays im Jahr 2015 wurde ein Entwicklungsprojekt V-Family ‚ECD‘ (Embedded Cockpit Display) gestartet mit dem Ziel, ein neues Display zu entwickeln sowie generell ein technologisches und ergonomisches Upgrade der grundsätzlich sehr erfolgreichen Produktfamilie durchzuführen.

Dieses Upgrade beinhaltet

- Eine Architekturänderung zu nur einem zentralen Rechnersystem, das sowohl die Therapie als auch die Bedienfunktionen steuert.
- Ein neues Display mit Verwendung eines kapazitiven Touch-Screens anstelle des bislang verwendeten resistiven Bildschirms.
- Ein neues Mainboard als Basis für die geänderte Rechnerarchitektur.
- Ein überarbeitetes GUI zur verbesserten Benutzerführung.



Bild 3: V-Familie ‚Classic‘




Bild 4: V-Familie ‚ECD‘

### 1.4. Zuverlässigkeitsabsicherung - Konzeptphase

Die bei Beatmungsgeräten besonders hohen Anforderungen an die Verfügbarkeit machten es erforderlich, das neue System mit den geänderten Funktionalitäten hinsichtlich seiner Zuverlässigkeit vor der Marktfreigabe zu bewerten. Einerseits konnte aufgrund der tiefgreifenden

Änderungen nicht vom Vorgängermodell auf das neue Design geschlossen werden, andererseits handelt es sich bei den Geräten um komplexe mechatronische Systeme, bei denen ein perfektes Zusammenspiel aller dazugehörigen Hardware- und Softwarekomponenten unter diversen Umgebungseinflüssen erforderlich ist. Zwischen der Firma Dräger und dem Fraunhofer Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF wurde daher ein Projekt gestartet, das zum einen das Ziel hatte, für das neue ‚ECD‘-System ein Zuverlässigkeits-Absicherungs-Konzept aufzustellen und umzusetzen sowie zweitens eine strategische Partnerschaft zur Steigerung der Zuverlässigkeit und Qualität medizinischer Geräte aufzubauen.

Im Rahmen der Konzeptphase wurde schnell deutlich, dass aufgrund der Komplexität des Geräts eine Vorsondierung und Priorisierung potenziell kritischer Subsysteme erforderlich war, die dann mit folgenden Maßnahmen näher untersucht werden sollten:

- Beaufschlagung des neu entwickelten Displays in einem Dauerlauf-Prüfstand durch Simulation der aus verschiedenen Nutzungsszenarien stammenden Betriebslasten (siehe nächstes Kapitel)
- Zu diskreten Zeiten Unterbrechung des Dauerlaufs und Durchführung folgender Prüfschritte:
  - o Generelle visuelle Inspektion der DUT bzgl. Auffälligkeiten
  - o Protokollierung von Auffälligkeiten in der Funktionsweise während des Dauerlaufs,
  - o Bedienbarkeit, Funktionalität und Haptik der kapazitiven Bedienoberfläche
  - o Systematische Erfassung einer möglichen Degradation in der Empfindlichkeit der Ansprache der kapazitiven Touch-Erkennung
  - o Systematische Erfassung in der Degradation/Veränderung der Performanz des Alarm-Lautsprechers
- Parallele Durchführung einer Fehlermöglichkeits- und Einflussanalyse (FMEA) für das Display.

## 2. Zuverlässigkeitsuntersuchung der ‚ECD‘-Bedieneinheit

Aus den vorangegangenen methodischen Betrachtungen und Recherchen wurde ein Testplan erarbeitet. Ziel war es, die Displays innerhalb eines Jahres mit den während einer Einsatzdauer von 10 Jahren auftretenden mechanischen, thermischen und klimatischen Lasten beaufschlagen zu können, und dabei die wichtigsten Funktionalitäten qualitativ und quantitativ zu erfassen und abzusichern. Zur Ermittlung der Belastungsprofile für die verschiedenen Tests

wurden Daten aus einschlägigen Normen als Grundlage genommen [1, 2] und mit messtechnisch erfassten Daten aus verschiedenen Nutzungsszenarien im klinischen Einsatz zu einem maßgeschneiderten Testprogramm zusammengeführt.

Zur regelmäßigen Überprüfung und Charakterisierung von Funktionen wie der Bedienbarkeit der integrierten Touch-Displays oder der gleichbleibenden Performanz eines akustischen Alarmsystems der Geräte, wurden am Fraunhofer LBF spezielle Prüfstände entwickelt und aufgebaut. Zwischen diesen Prüfzyklen wurden die Geräte auf einem Shaker in einer Klimakammer unterschiedlichen teilweise kombinierten Klima- und Vibrationsbelastungen ausgesetzt, welche die Belastungen im stationären und mobilen Einsatz sowie bei der Lagerung simulierten. Neben den betrachteten Hardwarekomponenten wurden dabei auch die dahinterliegenden Software Aktivitäten genauestens beobachtet, indem Logbücher von den Geräten exportiert und für die Analyse durch die Dräger SW-Entwicklung zur Verfügung gestellt wurden. So konnten die Langzeittests auch dazu beitragen, weitere Fehlerbehebungen und Verbesserungen in der Display-Firmware und Software der Geräte vornehmen zu können.

## 2.1. Testdesign und Durchführung

Zur Durchführung der experimentellen Untersuchung wurden die Displays von drei Beatmungsgeräten auf einen elektrodynamischen Schwingerreger in eine Klimakammer montiert, wobei die Beatmungsgeräte mittels einer Testlung während der Testzeit aktiv betrieben wurden. vgl. Bild 5. Dort wurden die Lastarten

- Vibration
- Schock
- Temperatur
- Feuchte

simultan auf die „Devices under Test“ (DUT) aufgeprägt, wobei die Geräte jeweils in der ‚Storage‘-Phase ausgeschaltet und für die ‚Operation‘-Phasen wieder eingeschaltet wurden.

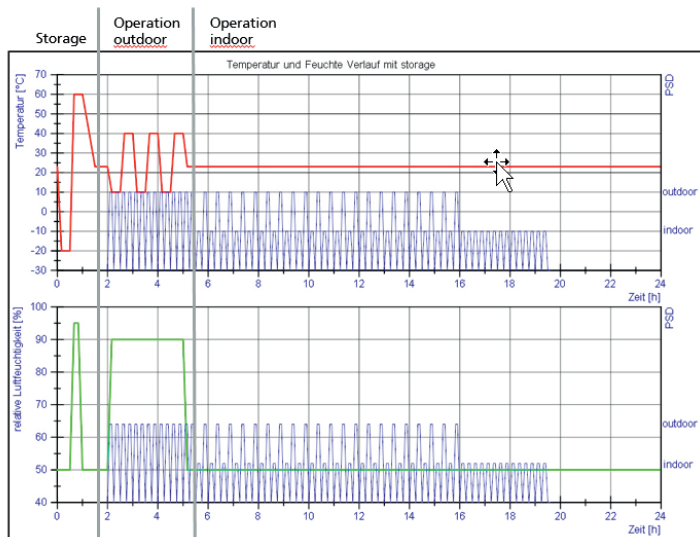
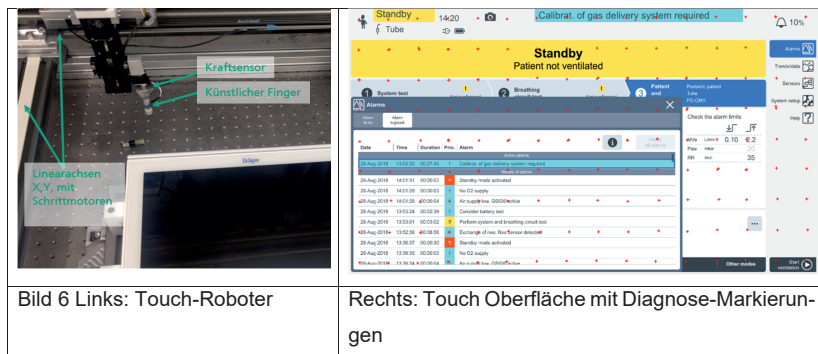


Bild 5 Oben: Testaufbau. Links im Bild die drei Grundgeräte; die Displays befinden sich auf dem in der Klimakammer (mittig im Bild) befindlichen Shaker.

Unten: Zeitlicher Verlauf einer 24-Stunden – Sequenz von spektraler Leistungsdichte der Vibrationsbeschleunigung (PSD) (blau), Temperatur (rot) und Feuchte (grün). Enthalten sind dabei Anteile für den stationären Klinikbetrieb (indoor), die mobile Nutzung (outdoor/indoor) und die Lagerung (storage).

## 2.2. Touch-Test

Um die zuverlässige Funktion des neuartigen kapazitiven Touch-Displays auf der gesamten Bedienoberfläche zu überprüfen, führte im Test nach je 1 Monat Vibrations- und Klimabelastung ein eigens dafür aufgebauter Prüfstand einen automatisierten Touch-Test mit allen ECDs durch. Im Rahmen dieses Touch-Tests wurden durch einen 3-Achsignen Touch-Roboter auf Schrittmotor-Basis auf jedem ECD an jeweils 144 (16x9) rasterförmig über die Fläche verteilten Punkten Touch-Events mit jeweils 2 unterschiedlich großen künstlichen Fingern durchgeführt. Um die Impedanz des menschlichen Fingers nachzustellen, waren die künstlichen Finger mit einer elektrisch leitfähigen Folie beklebt, die über eine RC - Schaltung mit Erdpotential verbunden war. Die Bedienkraft durch die künstlichen Finger wurde dabei mithilfe eines Kraftsensors geregelt; ein Display-interne Diagnose-Routine stellte erkannte Touch Events in Form roter Kreuze dar.



## 2.3. Akustik-Test

Das akustische Warnsystem des Beatmungsgerätes ist ein wesentlicher Bestandteil des Sicherheitskonzeptes für die zuverlässige Versorgung von beatmeten Patienten. Deshalb wurde die akustische Alarmierung ebenfalls 1x monatlich eingehend analysiert, um deren einwandfreie Funktion zu überprüfen bzw. mögliche Degradierungsmerkmale frühzeitig zu erkennen.



Mithilfe einer an das Displaygehäuse angepassten im 3-D Druck hergestellten schwingungsisolierenden Haltevorrichtung (Bild 7a) wurde für jede Messung ein Messmikrofon im Abstand von 25mm positioniert und ein akustischer Alarm des Gerätes in je 3 unterschiedlichen Lautstärken ausgelöst (50%,70%,90%) und aufgezeichnet. Bei dem Alarm handelt es sich um eine Tonfolge aus 2 verschiedenen Tönen in einem bestimmten Frequenzverhältnis. Zur Auswertung wurde nicht nur der absolute Schalldruckpegel herangezogen (Bild 7b), sondern auch eine Frequenzanalyse in Form von Wasserfalldiagrammen betrachtet (Bild 7c), wobei insbesondere harmonische Obertonreihen bewertet wurden.




Bild 7:

- Messaufbau: Messmikrofon in schwingungsisolierter Aufhängung mit definiertem Abstand (25mm)
- Darstellung der Amplitudenverläufe eines Alarmsignals in unterschiedlichen Lautstärken
- Wasserfalldiagramm eines Alarms mit einer bestimmten Lautstärke

So ließ sich neben der Lautstärke der abgegebenen Töne auch deren Klangcharakter beurteilen. Bei Degradationen des Lautsprechers oder dessen Anbindungsperipherie hätten sich hier Verzerrungen gezeigt, wie in Bild 8 zu erkennen ist. Bei der dargestellten Messung handelt es sich um einen bewusst provozierten Fehler, um damit die Sensitivität der Messmethode zu verifizieren.

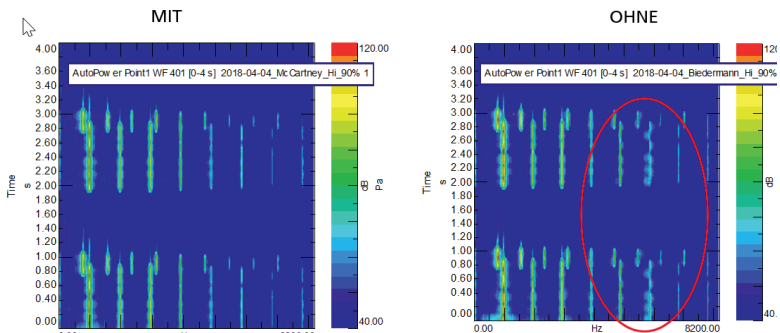


Bild 8: Repräsentatives Ergebnis: Unsauberkeiten in den Höherharmonischen deuten auf „Defekt“ des Lautsprechers hin (hier simuliert durch fehlendes Dämpfungsband)

## 2.4. Fehlermöglichkeits- und Einfluss-Analyse (FMEA)

Die experimentellen Untersuchungen wurden von einer FMEA begleitet. Experiment und FMEA sollten sich in der in Bild 9 dargestellten Weise ergänzen bzw. die Experimente einen Beitrag zu den Entdeckungsmaßnahmen liefern.

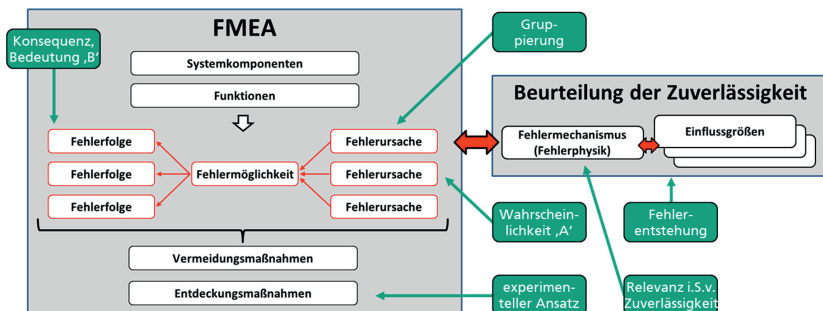


Bild 9: Zusammenspiel der FMEA und der experimentellen Arbeiten

Im Projekt wurde dazu zunächst seitens Dräger bestehende FMEA-Datenbestände homogenisiert. Es lagen partielle Datenbestände von Fehlermöglichkeits- und Auswirkungsanalysen bezogen auf das Display sowie in Grundzügen bezüglich des Gesamtsystems vor. Diese waren zum einen in der Softwareumgebung SCIO-FMEA der Firma Plato im Hause Dräger, sowie zum anderen in einer individuellen Methodikvariante in „Office Excel“ eines Zulieferers aufgesetzt worden. Aus diesen wurden darin beschriebene Fehlerursache- und -folgebeziehungen

extrahiert und in das Schema der Fehlernetze in der Softwareumgebung „IQ-FMEA“ der Firma APIS überführt. Dabei wurde insbesondere der Anteil seitens des Zulieferers auf den hierarchisch strukturierten Modellaufbau homogenisiert, sodass dieser kompatibel zu Fehlersymptomen des Gesamtsystems gemacht und in diesen integriert werden konnte (Bild 10).

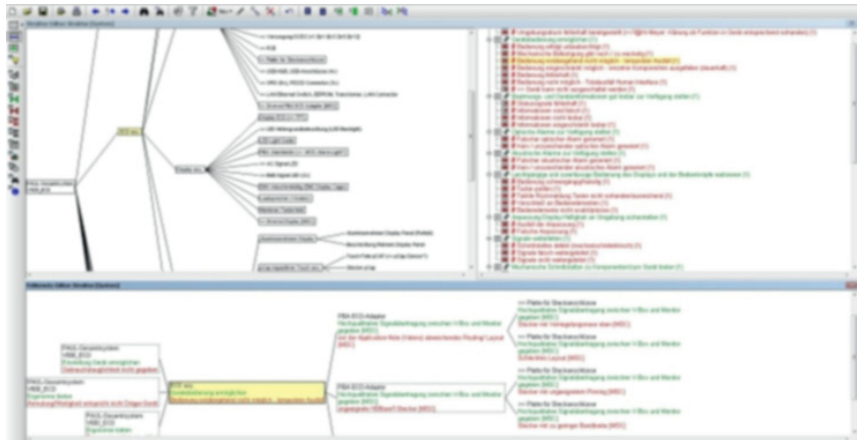


Bild 10: Überblick über die homogenisierte Produkt-FMEA des Systems „ECD“  
(aus Geheimhaltungsgründen ist die Darstellung verschwommen)

## 2.5. Testergebnis und FMEA-Bewertung

Während der einjährigen Testdauer von wurden zwölf Turnus-Prüfzyklen und ein Abschluss-test der Touchfunktion und des Lautsprechers vorgenommen.

Insgesamt wurden an den Displays nur kleinere Auffälligkeiten festgestellt, die jeweils umgehend zu Dräger kommuniziert und dort untersucht wurden. Die Analysen zeigten, dass diese Effekte nicht durch ein Langzeitverhalten der Display-Hardware bedingt waren, sondern durch die noch in Entwicklung befindliche Software verursacht wurden. An zwei Terminen wurde durch Dräger eine neue Software auf alle drei Systeme aufgespielt. Die Touchfunktion und die Funktion des Lautsprechers wurden jeweils vor und nachdem SW-Update protokolliert, dabei wurden keine Auffälligkeiten festgestellt.

Insgesamt zeigten weder die experimentelle Untersuchung noch die FMEA inakzeptable Qualitäts-Risiken für die Serienfreigabe des neuen Displays sondern unterstützten die positive Bewertung der Produktreife zur Marktfreigabe der neuen Gerätegeneration.

### 3. Test-basierte Reifung der SW-Stabilität des Gesamtsystems

#### 3.1. Zuverlässigkeitsuntersuchungen auf Systemebene

Für Zuverlässigkeits-Systemtests wurden 20 Geräte aufgebaut, die zeitgleich zu dem Display-Dauertest beim Fraunhofer LBF bei Dräger in teils automatisierten, teils manuell gesteuerten Dauerversuchen mit dem Schwerpunkt auf SW-Stabilität liefen. Diese Zuverlässigkeitsuntersuchungen werden bei Dräger in speziellen Reliability-Laboren („Q-Räume“) durchgeführt, die über entsprechende Infrastruktur zur Steuerung von kontrollierten Umgebungs- und Betriebsbedingungen verfügen. Dort wurden die Geräte per SW-Skripten kontinuierlich ‚ferngesteuert‘ in unterschiedlichen Anwendungsszenarien betrieben und regelmäßig durch Logbuchanalysen auf Fehlerzustände überprüft.

Parallel wurde im Rahmen der explorativen SW-Qualitätssicherung mit einigen Geräten ein Monkey-Testaufbau erstellt („King Louis“), bei dem durch einen externen PC zufällige Touch-Events (also Bedienvorgänge) simuliert und parallel auf einem weiteren Computer die Reaktion des Systems protokolliert werden konnte.



Bild 11: King Louis - Aufbau

### 3.2. Evolution durch Downsizing: vom Monkey zum MiniMonkey

Durch die relativ große Anzahl von Geräten im Q-Raum konnten auch selten stattfindende Fehlerzustände des Systems, insbesondere Warmstart-Ereignisse, beobachtet, analysiert und anschließend behoben werden. Nachdem jedoch auch in der vermeintlich ‚fertigen‘ SW-Version, die fehlerfrei durch den Monkey-Test gekommen war, noch weiterhin System-Reboots im Q-Raum beobachtet wurden und die Analysen keine Ursache für dieses Verhalten offenbaren konnten (‚Unknown-Reset‘-Symptom), wurde eine neue Teststrategie implementiert, um das Problem weiter einzukreisen.



Bild 12: V-Family ‚ECD‘ Testsysteme im Q-Raum

Statt über einen externen PC von außen das System zu belasten, wurde ein ‚MiniMonkey‘ in die Produkt-SW integriert. Dieser ermöglicht es, sowohl zufällige Touch-Events mit einstellbarer Periode (bis minimal 200 ms) auszulösen, als auch manuelle ‚echte‘ Bedienvorgänge aufzuzeichnen und anschließend wiederholt zu reproduzieren. Als integraler Teil der Produkt-SW konnte er sehr schnell auf alle Systeme im Q-Raum ausgerollt und aktiviert werden.

Mit Hilfe dieses MiniMonkeys war es schließlich möglich, als Ursache einen Fehler in einer Grafik-Routine des zugekauften Echtzeit-Betriebssystems aufzuspüren und beheben zu lassen. Die Suche nach der Ursache war dabei zwar sehr aufwändig und langwierig – es dauerte rund 4 Monate, bis der Fehler eindeutig zuzuordnen war und er schließlich auch im Quellcode nachvollzogen werden konnte –, als positiver Nebeneffekt konnten jedoch noch drei weitere Schwachstellen (2 potentielle Timing-Konflikte, ein Speicherleck) gefunden und behoben werden.

#### 4. Aktueller Stand der Feldrückmeldungen und Schlussfolgerungen

Die neue Generation der V-Familien-Beatmungsgeräte (Evita® V800, Evita® V600, Babylog® VN800, Babylog® VN600) bekam Ende März 2020 die Zulassung durch die Behörde (CE-Zeichen) und wurde ab Anfang April 2020 in Serie produziert und ausgeliefert. Durch den auf Grund der Pandemie weltweit massiv gestiegenen Bedarf an Beatmungsgeräten wurden die ursprünglich geplanten Produktionskapazitäten deutlich übertroffen; bis heute sind ca. 14.000 Einheiten im klinischen Einsatz. Die Rückmeldungen aus dem Feld sind auf einem sehr niedrigen Niveau und bestätigen damit die positive Qualitätsprognose aus den Untersuchungen bei Fraunhofer LBF und Dräger.

Die für das Projekt V-Family ‚ECD‘ durchgeführten experimentellen Maßnahmen zur Bewertung und Absicherung der Systemzuverlässigkeit – sowohl für die Komponente Display als auch für die Produkt-SW - haben sich bewährt und werden in zukünftigen Projekten weiter eingesetzt werden. Es ist geplant, den MiniMonkey funktional zu erweitern und ‚intelligenter‘ werden zu lassen, indem der Monkey z.B. Kenntnis über Passwörter bekommt, um Zugang zu geschützten Bereichen der Menüstruktur zu ermöglichen, und indem auch ‚verbotene Bereiche‘ definiert werden können, in denen keine Touch-Events ausgelöst werden.

#### 5. Referenzen

- [1] ISO 1471 Medizinprodukte – Risikomanagement Anwendung des Risikomanagements auf Medizinprodukte (ISO 14971:2007); Deutsche Fassung EN ISO 14971:2007
- [2] DMS IN 9040 – Test specification for mechanical environmental tests (Dräger-Werk-snorm)

# Simulation und Analyse mechanischer Bremsenschocks an Elektromotoren

Prof. Dr. **David Schepers**, M.Sc. **Lauri Bodenröder**,  
Hochschule Ruhr West, Mülheim/Ruhr;  
Prof. Dr. **Josef Börcsök**, Universität Kassel, Kassel;  
M.Sc. **Florian Rieger**, SEW-EURODRIVE GmbH & Co. KG, Bruchsal

## Kurzfassung

Beim Einfallen oder Öffnen einer Bremse an einem Elektromotor entstehen mechanische Schocks. Diese sogenannten Bremsenschocks können sicherheitsrelevante mechanische oder elektronische Komponenten beeinträchtigen. Die Beeinträchtigungen können hierbei irreversibel (d. h. in Form von mechanischen Schäden) oder reversibel (z. B. in Form von temporären Signalstörungen) sein. Besonders hiervon betroffen sind Drehgeber, welche zur Erfassung der Geschwindigkeit oder Position der Welle verwendet werden. Die derzeit angewandten Schockprüfverfahren nach IEC 60068-2-27 decken die real auftretenden Bremsenschock-Eigenschaften hinsichtlich Frequenz, Amplitude und Dauer nicht angemessen ab.

Daher werden in dieser Arbeit zunächst die charakteristischen Eigenschaften von Bremsenschocks vorgestellt und es wird argumentiert, dass das Pseudo-Geschwindigkeits-Schockantwortspektrum (Pseudo Velocity Shock Response Spectrum, PVSRS) die geeignetste mathematische Methode zur Quantifizierung der Schädigungswirkung von mechanischen Schocks ist. Anschließend werden Messdaten von realen Bremsmotoren analysiert. Auf Basis der PVSRS wird die Streuung der Schocks untersucht und eine Testspezifikation (mittleres Lastprofil) abgeleitet. Es werden Modifikationen an einem bestehenden Prüfstand zur Simulation von Bremsenschocks vorgestellt und die Streuung der aufgebrachten Belastung bewertet. Ferner werden zwei verschiedene Arten der Ansteuerung für den Prüfstand hinsichtlich der Qualität der Lastnachbildung untersucht. Hierfür wird die durch den Prüfstand generierte Belastung mit der zuvor definierten Testspezifikation verglichen und die Abweichung bewertet.

Langfristiges Ziel ist es, auf Basis dieses Vorgehens wissenschaftlich abgesicherte Prüfkriterien für ein Schockprüfverfahren zu definieren, das auf sicherheitsrelevante Komponenten an Elektromotoren angewendet werden kann. Es ist beabsichtigt, eine Aufnahme dieses Prüfverfahrens in eine internationale sicherheitstechnische Norm, wie die IEC 61800-5-3, anzustreben.


## 1. Einführung

Mechanische Einflüsse auf sicherheitsrelevante Komponenten finden in der Funktionalen Sicherheit aktuell wenig Beachtung. Hiervon betroffen sind beispielsweise Sicherheitsdrehgeber, welche zur Überwachung von Motorbewegungen in der Antriebstechnik eingesetzt werden. Beim Einfallen oder Öffnen einer Bremse an einem Elektromotor entstehen mechanische Schocks. Diese sogenannten Bremsenschocks breiten sich über das Motorgehäuse und die Motorwelle aus und können sicherheitsrelevante mechanische oder elektronische Bauteile und Komponenten beeinträchtigen. Die Beeinträchtigungen können hierbei irreversibel (d. h. in Form von mechanischen Schäden) oder reversibel (z. B. in Form von temporären Signalstörungen) sein [1]. Eine Beeinträchtigung der Geberfunktion oder Störung der Signalerfassung kann einen signifikanten Einfluss auf die Sicherheit des Systems haben.

Die derzeit angewandten Schockprüfungen nach IEC 61800-5-2 unter Prüfbedingungen nach IEC 61800-2 und Prüfverfahren nach IEC 60068-2-27 zum Nachweis der Unempfindlichkeit gegen Schockbelastungen decken die real auftretenden Bremsenschock-Eigenschaften hinsichtlich Frequenz, Amplitude und Dauer nicht angemessen ab, sodass gültige Grenzwerte für die real auftretenden Schockbelastungen aktuell nicht definiert sind. Die Folgen der unzureichenden normativen Anforderungen sind mögliche sicherheitskritische Ausfälle im Feld und Einschränkungen hinsichtlich der Verfügbarkeit des Antriebssystems.

## 2. Eigenschaften mechanischer Bremsenschocks

Bremsenschocks, welche durch Bremsbetätigungen am Elektromotor erzeugt werden, breiten



sich, wie in Bild 1 dargestellt, über das Motorgehäuse und die Motorwelle aus und können sicherheitsrelevante mechanische oder elektronische Bauteile und Komponenten beeinträchtigen. Besonders hiervon betroffen sind Drehgeber, welche am Ende der Motorwelle befestigt sind und zur Erfassung der Geschwindigkeit oder Position der Welle dienen.

Bild 1: Schockausbreitung am Elektromotor in Anlehnung an [1]



Bild 2 zeigt einen typischen Bremsenschock, welcher mittels eines piezoelektrischen Beschleunigungssensors am Ende der Motorwelle in radialer Richtung (vgl. Bild 1) gemessen wurde. Die Bremse wurde bei dem dargestellten Schock bei ca. 500 Umdrehungen pro Minute betätigt. Die Schockdauer beträgt 10 bis 15 ms bei einer maximalen Amplitude von circa 500 g.




Bild 1: Typischer Bremsenschock

### 3. Klassifizierung des Bremsenschock-Schweregrads

Der Schweregrad eines Bremsenschocks ist von mehreren Faktoren abhängig. Zum einen hängt dieser von den Eigenschaften der Bremse selbst ab, d. h. von der Bremskraft und der Größe des Luftspalts zwischen der Bremsscheibe und der Ankerscheibe. Je größer dieser Luftspalt bzw. die Bremskraft ist, desto höher ist die beobachtete Schwere des Schocks. Zum anderen hängt die Schwere des Schocks von der Rotationsgeschwindigkeit der Motorwelle ab. Ein Einfallen der Bremse bei Stillstand ist weniger schwerwiegend als bei einer rotierenden Welle. Wobei bei Federdruckbremsen ab dem Bereich von 150 - 500 bis ca. 6000 Umdrehungen pro Minute keine signifikante Zunahme des Schweregrads des Schocks mehr messbar ist [1].

Um den Schweregrad eines Bremsenschocks zu bewerten, ist die Betrachtung der Zeitverläufe der gemessenen Beschleunigung, Geschwindigkeit oder Auslenkung nicht sinnvoll, da die Anregung der Eigenmoden für die Schädigung von Bauteilen in der Schockumgebung verantwortlich ist. Völlig unterschiedliche Zeitverläufe von mechanischen Schocks können daher ein ähnliches Schädigungspotential aufweisen [2].

Aus den genannten Gründen ist eine Betrachtung von Schockantwortspektren aufschlussreicher. Es hat sich in diesem Zusammenhang gezeigt, dass die Verwendung des

Pseudo-Geschwindigkeits-Schockantwortspektrums (Pseudo-Velocity Shock Response Spectrum, PVSRS) eine geeignete mathematische Methode zur Quantifizierung der Schädigungswirkung von mechanischen Schocks ist, da die Pseudo-Geschwindigkeit proportional zu mechanischer Spannung ist und die Pseudo-Geschwindigkeit den Energiegehalt des Schocks aufzeigt [3, 4].

Derzeit werden Schockprüfungen für Drehgeber mit Halbsinus-Anregungen nach IEC 60068-2-27 durchgeführt. Allerdings können die Eigenschaften realer mechanischer Bremsenschocks durch Halbsinus-Anregungen nur unzureichend reproduziert werden, da Bremsenschocks das Ergebnis von überlagerten Schwingungen sind, die einen breiten Frequenzbereich abdecken.

In Bild 3 sind die PVSRS des, in Bild 2 dargestellten, Bremsenschock (schwarz) mit einem Halbsinus-Schock (100 g/6 ms; rot) in ein Vier-Koordinaten-Diagramm geplottet. Im Diagramm ist auf der Abszisse die Frequenz, auf der Ordinate die Pseudo-Geschwindigkeit und auf den Diagonalen die Beschleunigung bzw. Auslenkung ablesbar.

Das PVSRS eines Bremsenschocks zeigt typischerweise einen steigenden Verlauf im unteren und einen fallenden Verlauf im oberen Frequenzbereich. Im dazwischenliegenden Frequenzbereich entsteht ein Plateau. Es ist deutlich zu erkennen, dass dieser Halbsinus-Schock die hochfrequenten Anteile eines Bremsenschocks nicht angemessen abbildet und die niederfrequenten Anteile überrepräsentiert sind. Hauptproblem ist jedoch die Breite des Plateaus des Bremsenschocks. Diese kann auch durch eine andere Zeitdauer des Halbsinus-Schocks nicht erreicht werden.

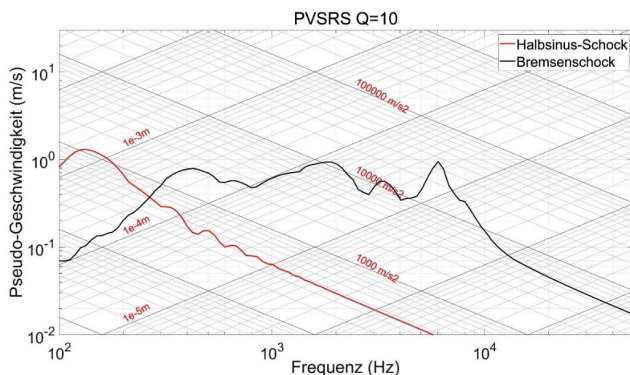


Bild 3: MaxiMax-PVSRS eines Halbsinus-Schocks (rot) und eines Bremsenschocks (schwarz)

Mit den Prüfverfahren nach IEC 60068-2-27 können daher keine zufriedenstellenden Prüfungen durchgeführt werden, um Schäden an sicherheitsrelevanten Bauteilen durch Schockeinwirkung im Betrieb zu vermeiden.

#### 4. Analyse von Bremsenschocks

Nachfolgend werden die durch einfallende Bremsen an drei unterschiedlichen Elektromotor/Bremse-Konfigurationen verursachten Bremsenschocks mittels der Pseudo-Geschwindigkeits-Schockantwortspektren analysiert und eine Testspezifikation für diese Konfigurationen hergeleitet. Die Konfigurationen unterscheiden sich sowohl in den Eigenschaften der Bremsen als auch der Elektromotoren und werden im Folgenden mit EBK200, EBK600 und EBK800 bezeichnet. Es wurden jeweils 20 Messungen pro Elektromotor/Bremse-Konfiguration durchgeführt, bei welchen die Bremse bei einer Rotationsgeschwindigkeit der Motorwelle von 500 Umdrehungen pro Minute betätigt wurde. Die in Bild 4 dargestellten Pseudo-Geschwindigkeits-Schockantwortspektren wurden anhand von Beschleunigungsmessdaten gemäß ISO 18431-4 mit einem Q-Faktor von zehn berechnet. Alle Beschleunigungsmessdaten wurden am Ende der Motorwelle in radialer Richtung mittels piezoelektrischem Beschleunigungssensor aufgenommen und mit einem FFT-Bandpassfilter von 100 Hz bis 10.000 Hz gefiltert.

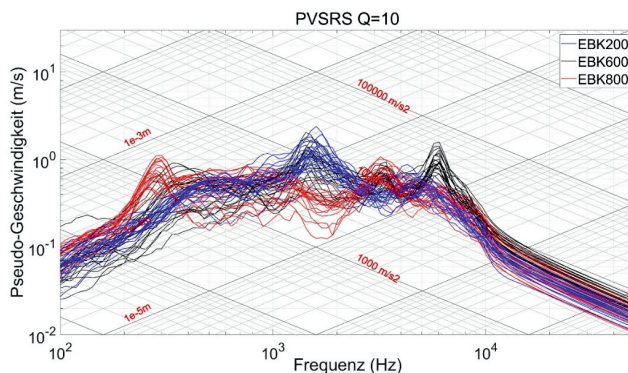


Bild 2: Pseudo-Geschwindigkeits-Schockantwortspektren aller Bremsenschock-Messungen

Aus Bild 4 ist ersichtlich, dass die Beschleunigungsmessdaten der drei unterschiedlichen Elektromotor/Bremse-Konfigurationen zu ähnlichen PVSRs-Verläufen führen und, dass die PVSRs-Verläufe der Bremsenschocks der einzelnen Konfigurationen unter identischen Bedingungen stark streuen. Die Streuung der Antwortspektren je Konfiguration ist in Bild 3

über den Frequenzbereich von 100 Hz bis 10.000 Hz dargestellt. Die Streuung ist hierbei die Spannweite zwischen dem größten und dem kleinsten Wert in Dezibel. Die Streuung der EBK600 (schwarz) Konfiguration ist besonders im unteren Frequenzbereich stark ausgeprägt. Abweichungen von über 17 Dezibel sind bis etwa 400 Hz zu beobachten. Danach nimmt die Spannweite der Messwerte ab. Die Konfigurationen EBK200 (blau) und EBK800 (rot) weisen im mittleren Frequenzbereich von 400 Hz bis 1600 Hz die größten Schwankungen auf. Über den gesamten Frequenzbereich betrachtet, ist die über äquidistante Punkte berechnete mittlere Streuung der drei Konfigurationen allerdings sehr ähnlich. Für EBK200 beträgt diese 7,7 dB, für EBK600 8,0 dB und für EBK800 8,7 dB.

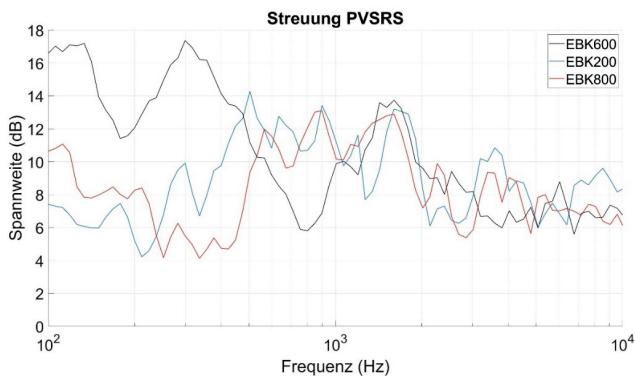


Bild 3: Streuung der PVSRS der Elektromotor/Bremse-Konfigurationen

Aufgrund der starken Streuung ist zur Herleitung einer Testspezifikation zur Nachbildung der Lastprofile der realen Bremsenschocks am Prüfstand eine Mittelung der einzelnen Elektromotor-Bremse-Konfigurationen sowie die Definition von Toleranzbändern sinnvoll. In Bild 6 sind die gemittelten PVSRS der einzelnen Konfigurationen dargestellt. Da das Schädigungspotential eines mechanischen Schocks von den angeregten Eigenmoden abhängt und mit der Pseudo-Geschwindigkeit korreliert, wird für vergleichbare PVSRS-Verläufe ein ähnliches Schädigungspotential erwartet. Die Bremsenschocks der drei Elektromotor/Bremse-Konfigurationen zeigen demzufolge ein ähnliches Schädigungspotential.

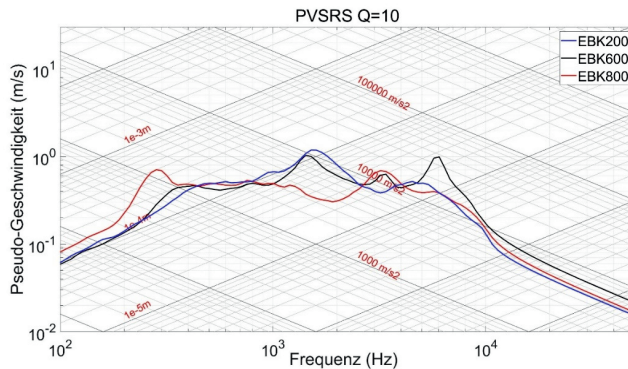


Bild 4: Mittlere Profile der drei Elektromotor/Bremse-Konfiguration

Aus Gründen des Testaufwandes ist es sinnvoll, ein mittleres Lastprofil aus den drei PVRSR-Verläufen zu definieren und so den Testaufwand zu verringern. Es wird vermutet, dass ein Drehgeber, der der Schockbelastung standhält, welche durch das PVRSR des mittleren Lastprofils charakterisiert wird, in sicherheitstechnischen Applikationen in Kombination mit einem der drei Elektromotor/Bremse-Konfigurationen eingesetzt werden kann. Es ist somit nur noch die Durchführung einer anstatt drei Dauerlaufstretreihen notwendig.

In Bild 7 ist das mittlere Lastprofil, gebildet aus den mittleren PVRSR-Profilen aus Bild 6, inklusive der Toleranzbänder für die durchzuführenden Dauerlaufstests für einfallende Bremsen bei einer Rotationsgeschwindigkeit der Motorwelle von 500 Umdrehungen pro Minute in radialer Richtung dargestellt.

Das  $\pm 4$  dB-Toleranzband resultiert aus der mittleren Spannweite der PVRSR der Bremsenschocks. Die Wahl der Toleranzbänder soll durch künftig noch durchzuführende Untersuchungen (Dauerlaufstests) weiter begründet und verifiziert werden. Die mittleren Abweichungen über den Frequenzbereich von 100 Hz bis 10.000 Hz der mittleren Profile (Bild 6) vom mittleren Lastprofil (Bild 7) betragen 0,8 dB (EBK200), -1,3 dB (EBK600) und 1,2 dB (EBK800). Das mittlere Lastprofil bildet somit die Schockbelastungen der drei Elektromotor/Bremse-Konfigurationen gut ab, wobei die Schädigungswirkung bezogen auf die EBK600 unterrepräsentiert und bezogen auf die EBK800 sowie die EBK200 überrepräsentiert ist. Die Testspezifikation resultiert demnach aus dem in Bild 7 gezeigten mittleren Lastprofil sowie den maximal zu erwarteten Lastzyklen.

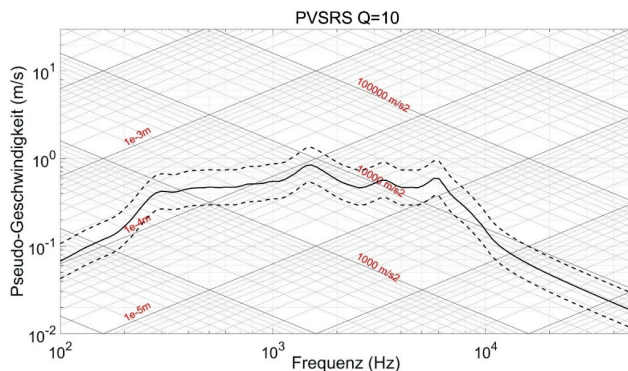


Bild 5: Mittleres Lastprofil mit 4 dB-Toleranzbändern

## 5. Prüfstand zur Simulation von Bremsenschocks

In [5] wurde der in Bild 6 schematisch dargestellte Prüfstand zur Simulation von mechanischen Bremsenschocks vorgestellt, mit dem Lastprofile von realen Bremsenschocks nachgebildet werden können. Der zu prüfende Geber wird hierbei mit der Welle und dem Stator des Prüfstands verbunden. Die Schockanregung wird mittels zweier auf die Welle treffender Aktoren und einen auf den Stator wirkenden Aktor erzeugt, wobei die Antriebe die Aktoren bis zum Auftreffen auf die Welle bzw. den Stator fahren.




Bild 6: Schematische Darstellung eines Prüfstandes zur Bremsenschock-Simulation [5]

Mit dem Prüfstand können mechanische Schocks generiert werden, die das Pseudo-Geschwindigkeits-Schockantwortspektrum von realen Bremsenschocks im Frequenzbereich über 400 Hz bis 10.000 Hz gut nachbilden können. Im Frequenzbereich unter 400 Hz sind allerdings verhältnismäßig große Abweichungen zu beobachten, bedingt durch niederfrequente Nachschwingungen im Beschleunigungssignal des Schocks. Durch

Modifikation der Ansteuerung der auf die Welle treffenden Aktoren können diese Nachschwingungen deutlich reduziert werden. Die Antriebe fahren die Aktoren nicht mehr bis zum Auftreffen auf die Welle, sondern werden zuvor stromlos geschaltet. Die Beschleunigungssignale der beiden am Prüfstand erzeugten Schocks sind in Bild 9 (Aktoren bis auf die Welle gefahren) und in Bild 10 (Aktoren zuvor stromlos geschaltet) dargestellt<sup>1</sup>. Es ist zu erkennen, dass die ab etwa 35 Millisekunden (Bild 9) auftretenden Nachschwingungen nicht mehr im Signal vorhanden sind. Die Schockdauer wird hierdurch von 30 ms auf 10 ms verringert, sodass mehr Schocks pro Zeiteinheit am Prüfstand durchgeführt werden können.




Bild 7: Beschleunigungssignal des Prüfstandschock (Aktoren bis auf die Welle gefahren)




Bild 8: Beschleunigungssignal des Prüfstandschock (Aktoren zuvor stromlos geschaltet)

Die erzielten Verbesserungen im Beschleunigungssignal des Prüfstandschocks spiegeln sich ebenfalls in der PVSRS wider. In Bild 11 sind die Antwortspektren des mittleren Lastprofils aus Bild 5 sowie die Antwortspektren der mit dem Prüfstand generierten Schocks (Aktoren bis

<sup>1</sup> Hinweis: Bild 9 und Bild 10 weisen unterschiedliche Zeitachsen auf



auf die Welle gefahren (blau) und Aktoren zuvor stromlos geschaltet (rot)) gezeigt. Die PVRSRS der Prüfstandschocks wurden ebenfalls aus jeweils 20 Messungen gemittelt und nach dem gleichen Vorgehen, wie in Abschnitt 4 beschrieben, berechnet.




Bild 9: Gemittelte PVRSRS des mittleren Lastprofils und der Prüfstandschocks

Die absoluten Abweichungen des Prüfstandschocks vom mittleren Lastprofil der realen Bremsenschocks im Frequenzbereich von 100 Hz bis 400 Hz konnten durch die Modifikation der Ansteuerung deutlich reduziert werden, wie in Bild 12 zu erkennen ist. Die über äquidistante Punkte berechnete mittlere Abweichung in diesem Bereich konnte von 11,8 dB auf 4,6 dB verringert werden. Im Frequenzbereich von 400 Hz bis 10.000 Hz konnte die mittlere Abweichung ebenfalls von 4,1 dB auf 3,2 dB reduziert werden.




Bild 10: Absolute Abweichungen vom mittleren Lastprofil



Der verbesserte Prüfstandsschock bildet das mittlere Lastprofil der realen Bremsenschocks innerhalb der definierten Toleranzbänder zufriedenstellend nach (Bild 13). Die mittlere Streuung der Prüfstandsschocks beträgt 2,9 dB und ist somit als gering im Vergleich zur Streuung der realen Bremsenschocks zu bewerten. Die mittlere Abweichung des gemittelten Prüfstandsschocks vom mittleren Lastprofil über den Frequenzbereich von 100 Hz bis 10.000 Hz beträgt -2,5 dB, wobei im Frequenzbereich von 100 Hz bis 400 Hz die mittlere Abweichung 4,6 dB und im Frequenzbereich von 400 Hz bis 10.000 Hz -2,7 dB beträgt. Im unteren Frequenzbereich ist die durch den Prüfstand erzeugte Schockbelastung im Mittel somit um den Faktor 1,7 höher als durch das mittlere Lastprofil definiert und im oberen Frequenzbereich um den Faktor 1,4 niedriger. Weitere Anpassungen am Prüfstand sind daher notwendig, um die Abweichungen zu reduzieren, da besonders im oberen Frequenzbereich die Gefahr besteht, die tatsächlichen Schockbelastungen nicht ausreichend abzubilden.




Bild 11: Prüfstandsschocks und mittleres Lastprofil

## 6. Fazit und Ausblick

Im ersten Teil der Arbeit wurden die wesentlichen Charakteristiken von Bremsenschocks beschrieben und es wurde erläutert, warum das Pseudo-Geschwindigkeits-Schockantwortspektrum (PVSRs) ein geeignetes Kriterium zur Beschreibung des Schweregrads von mechanischen Bremsenschocks ist. Im zweiten Teil wurde gezeigt, dass die Bremsenschocks dreier Elektromotor/Bremse-Konfigurationen ähnliche Verläufe aufweisen und daher eine allgemeine Testspezifikation zur Verringerung des Testaufwands hergeleitet werden kann. Hierzu wurde ein mittleres Lastprofil definiert. Außerdem wurden Modifikationen in der Ansteuerung des bestehenden Prüfstands zur Simulation von

mechanischen Schocks dargelegt, durch welche eine signifikante Verbesserung bei der Nachbildung von realen Bremsenschock-Eigenschaften erzielt werden konnte.

In zukünftigen Forschungsarbeiten sollen weitere Messungen an realen Bremsmotoren durchgeführt werden, um eine bessere Datenbasis für ein repräsentatives Lastprofil zu erhalten. Ziel ist es dabei, ein einziges Lastprofil (und damit eine einzige Prüfung) zu definieren, mit dem grundsätzlich die Eignung von Drehgebern für den Einsatz an Bremsmotoren bewertet werden kann. Dabei ist jedoch zu klären, inwieweit das mittlere Lastprofil eine gute Annahme für eine repräsentative Belastung ist und ob nicht beispielsweise eine Hüllkurve über die PVSRS herangezogen werden muss, auch wenn diese schwieriger nachzubilden ist. Durch Dauerlauftests mit dem Prüfstand sollen dann die Ergebnisse validiert werden und die Belastbarkeit sicherheitsrelevanter Komponenten gegenüber mechanischen Bremsenschocks bestimmt werden.

## 7. Literaturangaben

- [1] F. Rieger und B. Hagemann, „Mechanical shocks caused by brakes on electric motors,“ SEW-Eurodrive GmbH & Co KG, Bruchsal.
- [2] ECSS, „Space engineering - Mechanical shock design and verification handbook,“ ESA Requirements and Standards Division, Noordwijk, 2015
- [3] H. A. Gaberson, „Pseudo Velocity Shock Spectrum Rules for Analysis of Mechanical Shock,“ 2007..
- [4] H. A. Gaberson, „Shock Severity Estimation,“ Sound & Vibration - January 2015 - 45th Anniversary Issue, pp. 12-19, 2012.
- [5] D. Schepers, L. Bodenröder, J. Börcsök und F. Rieger, „Simulation and Mathematical Description of Mechanical Shocks Caused by Brake Actuation on Electric Motors,“ International Journal of Circuits, Systems and Signal Processing, 2020.

# Effiziente Zuverlässigkeitsabsicherung durch Berücksichtigung von Simulationsergebnissen am Beispiel einer Hochvolt-Batterie

**A. Grundler, M. Dazer, B. Bertsche,**  
Institut für Maschinenelemente, Universität Stuttgart;  
**M. Göldenboth, F. Stoffers,** Mercedes-Benz AG, Sindelfingen

## Kurzfassung

Zur Absicherung der Zuverlässigkeit eines Produktes bedarf es physischer Tests um die Funktionstüchtigkeit über eine festgelegte Nutzungszeit nachzuweisen. Geringe Entwicklungszeiten und -kosten sowie gestiegene Produkthaftung resultieren in verschärften Randbedingungen, wodurch bei der Planung, Durchführung und Auswertung solcher Zuverlässigkeitsnachweistests immer im Zielkonflikt zwischen Genauigkeit, Kosten und Zeit zu agieren ist. Um diesem Zielkonflikt zu begegnen, existieren Vorkenntnismodelle [1–6], die es ermöglichen die Testergebnisse durch Vorkenntnis zu präzisieren. Großes Potential bieten dabei Lebensdauersimulationen, welche beispielsweise bereits zur Unterstützung der Produktentwicklung und dem Kenntnissgewinn über das spätere Verhalten im Feld in Unternehmen bestehen und genutzt werden. Ergebnisse einer solchen Simulation werden aktuell aus zuverlässigkeitstechnischer Sicht jedoch nicht weitreichend verwendet. Die Herausforderung zur Nutzung, besteht in der Überführung dieser Simulationsergebnisse in eine für die konkrete Anwendung notwendige Form, bestehend aus einer Zuverlässigkeit zur geforderten Lebensdauer mit Aussagewahrscheinlichkeit.

Am Beispiel einer Degradationssimulation von Hochvolt-Batterien wird demonstriert, wie eine solche, aus zuverlässigkeitstechnischer Sicht wertvolle Information gewonnen werden kann. Dabei können die zugrundeliegenden Messungen des Berechnungsmodells verwendet werden, um der Information eine Aussagewahrscheinlichkeit zuzuweisen und damit die inhärente Unsicherheit der Belastbarkeitsinformation beschreiben zu können. Mittels eines Bootstrap-Verfahrens [7], [8] werden Zuverlässigkeitsverteilungen gewonnen, die anschließend mit den Ergebnissen aus physischen Tests zur Zuverlässigkeitsabsicherung kombiniert werden können. Dabei wird der Satz von Bayes [9] verwendet, welcher diese

Kombination über bedingte Wahrscheinlichkeiten vornimmt. Die Untersuchungen zeigen, dass die Berücksichtigung von Simulationsergebnissen großes Potential bietet, um den Konflikt der Zuverlässigkeitsabsicherung zu entschärfen. Ein Vergleich mit der Methode des erweiterten Weibayes-Ansatzes [10] zeigt darüber hinaus, dass die in dieser Arbeit entwickelte Methode großes Potential hinsichtlich einer effizienten Zuverlässigkeitsabsicherung bietet. Dies spiegelt sich zum einen in der höheren Informationsgüte der in eine Zuverlässigkeitsinformation übersetzten Simulationsergebnisse, als auch der Verknüpfung dieser Ergebnisse mit weiteren Informationen aus physischen Tests verschiedener Art wider.

## 1 Motivation

Lithium-Ionen-Akkumulatoren bilden eine Schlüsseltechnologie zur Speicherung von Energie, sodass insbesondere in Kraftfahrzeugen lokale Emissionen vermieden werden können. So wird auf der einen Seite ein Beitrag zum Umweltschutz ermöglicht und andererseits können Emissionsziele der Hersteller erreicht werden. Verglichen mit herkömmlichen Technologien, wie beispielsweise dem Antriebsstrang mit Verbrennungsmotor, bedarf die Hochvolt-Batterie als Akkumulator in Kraftfahrzeugen besonderen Entwicklungsaufwand, da auf weniger historische Erfahrung und Daten zurückgegriffen werden kann. Dabei sind Lebensdauersimulationen sehr wertvoll. So können bereits in frühen Entwicklungsphasen Konzepte bewertet und das Verhalten im Betrieb bezüglich Funktionalität und Lebensdauer vorhergesagt werden. Wesentlicher Vorteil der Simulation gegenüber physischer Tests ist der deutlich schnellere und kostengünstigere Erkenntnisgewinn über das Alterungsverhalten und die Lebensdauer von Hochvolt-Batterien in verschiedenen Konzept- und Einsatzszenarien. Dies ermöglicht eine deutlich detailliertere Untersuchung von relevanten Belastungsgrößen und deren Effekte auf die Batterie.

In der Absicherung einer Hochvolt-Batterie, als auch anderen Produkten, ist stets im Zielkonflikt zwischen Genauigkeit, Kosten und Zeit zu agieren. Dieser wird durch neue, komplexe Produkte und gestiegene Produkthaftung zusätzlich verschärft. Insbesondere die Absicherung neuer Technologien, stellt aufgrund mangelnder Erfahrung eine Herausforderung dar. Dem stehen jedoch sehr gut validierte Simulationsmodelle zur Verfügung, um das Verhalten dieser neuen Technologien bereits in einem sehr frühen Stadium des Entwicklungsprozesses abzuschätzen.

Um eine effiziente Absicherung des Gesamtprodukts zu gewährleisten, können die Ergebnisse einer solchen Simulation verwendet werden. Zur Parametrisierung der Simulationsmodelle wurden Belastbarkeitsmessungen an einzelnen Zellen der Batterie durchgeführt. In diesem

Kontext kann die Simulation als Transformation dieser empirischen Erkenntnisse auf das aktuelle Produkt im Spannungsfeld zwischen Belastung und Belastbarkeit verstanden werden. Um die Simulationsergebnisse in eine für den Zuverlässigkeitsnachweis verwertbaren Information aus Lebensdauerquantil mit Aussagewahrscheinlichkeit übersetzen zu können, existieren einige wenige Ansätze [2], [11], welche für den konkreten Anwendungsfall angepasst werden müssen. Der Ansatz nach Krolo [2] verwendet zwar ebenso den Satz von Bayes und beschreibt Vorwissen in Form einer Betaverteilung der Zuverlässigkeit. Bezüglich der Berücksichtigung von Berechnungsergebnissen werden jedoch synthetische Verteilungen statt einer Betaverteilung konstruiert, welche die direkte Ableitung der Aussagewahrscheinlichkeit aus den Simulationsergebnissen vermissen lassen. Der Ansatz nach Grundler et al. [11] hingegen ermöglicht die Fassung der Information aus Lebensdauersimulationen mittels dem Wöhlermodell mit Aussagewahrscheinlichkeit. Eine Anpassung auf weitere Fälle wie beispielsweise Degradationssimulationen ist jedoch notwendig da hier ein komplexeres Schadensmodell zugrunde liegt. Aus diesem Grund muss das Vorgehen für die Simulation der Hochvolt-Batterie erweitert und angepasst werden. Die erweiterte Weibayes-Methode nach Romer [5] erlaubt die Berücksichtigung von Vorkenntnissen aus Lebensdauerberechnungen. Diese fließen dabei jedoch lediglich über eine berechnete charakteristische Lebensdauer einer Weibullverteilung ohne Aussagewahrscheinlichkeit ein, weswegen relevante, verfügbare Informationen der Simulation keine Berücksichtigung finden.

## 2 Lebensdauersimulation der Hochvolt-Batterie

Zur Vorhersage des Betriebs- und Ausfallverhaltens der Hochvolt-Batterien im Feld, werden Degradationssimulationen durchgeführt. Die dabei verwendeten Simulationsmodelle sind mit Messungen an einzelnen Zellen der Batterie parametrisiert und ermöglichen die Abbildung mehrerer Schadensmechanismen, welche sich durch einen Kapazitätsverlust, oder einem Leistungsverlust äußern. Dabei werden unter anderem zeitliche Einflüsse, Temperatureinflüsse, Strombelastung, stöchiometrische Vorgänge sowie Zellspannungen berücksichtigt. Kapazitätsverluste führen in Kraftfahrzeugen zu einer geringeren Reichweite, was vom Kunden negativ wahrgenommen wird und in extremen Fällen zu einem Imageverlust des Unternehmens führen kann.

Die Degradationssimulation ermöglicht dabei die Übersetzung der an den Zellen der Batterie durchgeführten Messungen, welche die Belastbarkeit beschreiben, und den aus Feldmessungen bekannten Lastkollektiven, welche die Belastung beschreiben, in den aktuell relevanten Fall von Batterie- und Fahrzeugkonzepten. Diese soll neben der Bewertung in der

Entwicklung zusätzlich zur Absicherung der Hochvolt-Batterie verwendet werden. Sie zeigt auf, wie sich das Fahr- und Ladeverhalten der Kunden auf die Zellalterung in Form eines Kapazitätsverlustes auswirken. Die Degradationsmodelle der hier betrachteten Simulation wurden mit 8 Messungen an Batteriezellen parametrisiert, welche die Alterungsresistenz hinsichtlich der Kapazität quantitativ unter einheitlichen Belastungsbedingungen abbilden. Die Feldbelastung wurde durch Messungen im realen Betrieb von 21.000 Fahrzeugen eines Vorgängerprodukts gewonnen, welche damit das Lastkollektiv darstellen. Die wesentlichen Informationen zur verwendeten Simulation sind in Tabelle 1 festgehalten.

Tabelle 1: Informationen zur verwendeten Degradationssimulation der Hochvolt-Batterie.

Input	Output	Wesentliche Parameter	
Zellmessungen und Feldbelastung der jeweiligen Messfahrzeuge	Restkapazität der Batterien der Feldfahrzeuge in Abhängigkeit des kumulierten Energiedurchsatzes	Anzahl der Zellmessungen zur Parametrisierung des Simulationsmodells	$n_1 = 8$
		Anzahl Feldmessungen	$n_2 = 21.000$

In Bild 1 ist das Ergebnis der Simulation dargestellt. Es liefert die Kapazität (auch State of Health (SoH) genannt) der Batterie für alle 21.000 simulierten Fahrzeuge, aufgetragen über dem kumulierten Energiedurchsatz der Batterie. Da die Absicherung der Batterie auch kalendarische Alterung berücksichtigen soll, welche nicht durch eine gefahrene Strecke abgebildet werden, wird dieser Energiedurchsatz als Lebensdauergröße verwendet.




Bild 1: Ergebnis der Degradationssimulation der Hochvolt-Batterie.

Die hier vorgestellten Werte und Parameter der Simulation entsprechen qualitativ den tatsächlichen. Aufgrund von Geheimhaltungsvereinbarungen wurden diese jedoch verändert. Das Verhalten sowie die relevanten Zusammenhänge für die durchgeführten Untersuchungen entsprechen jedoch der Realität.

### 3 Zuverlässigkeitsaussage der Lebensdauersimulation

Die aus der Simulation gewonnenen Werte der Kapazität der Hochvolt-Batterie erlauben eine Aussage über das Lebensdauerquantil. Dieses kann mittels einer statistischen Auswertung der Kapazitätswerte in Abhängigkeit der Lebensdauer gewonnen werden. Das Lebensdauerziel der hier betrachteten Batterie ist über den kumulierten Energiedurchsatz definiert und beträgt  $t_{Ziel} = 470 \text{ MWh}$ . Die Abnahme des State of Health um 20 % kann zugelassen werden, da dadurch die volle Funktionsfähigkeit des Fahrzeugs garantiert werden kann. Aus diesem Grund wird die Batterie aus zuverlässigkeitstechnischer Sicht als ausgefallen betrachtet, wenn sie bei einem kumulierten Energiedurchsatz von  $t_{Ziel} = 470 \text{ MWh}$  eine Kapazität aufweist, die kleiner ist als 80 % der Ursprungskapazität. Als Zuverlässigkeitsziel ist eine Zuverlässigkeit  $R_{Ziel}(t_s) = 90 \%$  bei einer Aussagewahrscheinlichkeit von  $P_{A,Ziel} = 90 \%$  festgelegt.

Die statistische Auswertung der Ergebnisse der Simulation für dieses Versagenskriterium ist in Bild 2 zu sehen.




Bild 2: Weibullanalyse der Simulationsergebnisse der Hochvolt-Batterie, entsprechend dem Versagenskriterium von SoH < 80 %.

Dabei werden die simulierten Fahrzeuge bezüglich des Ausfallkriteriums als zensiert betrachtet, wenn diese die Kapazität von 80 % nicht unterschreiten (siehe Bild 1). Die Daten werden mit Hilfe der Weibullverteilung [1] ausgewertet und es ergeben sich durch eine Maximum-Likelihood-Schätzung (MLE) [12] eine charakteristische Lebensdauer von  $T = 596,37 \text{ MWh}$  und ein Formparameter von  $b = 9,598$ . Die Wahrscheinlichkeit, dass die Batterie zur geforderten Lebensdauer noch mindestens eine Kapazität von 80 % aufweist berechnet sich danach zu  $R(t_s) = 90,33 \%$ . Eine Zuverlässigkeitsaussage bedarf jedoch einer Aussagewahrscheinlichkeit, welche diese einfache statistische Auswertung der Simulationsergebnisse vermissen lässt. Um den Ergebnissen eine Aussagewahrscheinlichkeit zuzuweisen, bedarf es weiterer Schritte, welche im Folgenden vorgestellt werden.

#### **4 Zuverlässigkeitsaussage der Lebensdauersimulation mit Aussagewahrscheinlichkeit**

Um der erfolgten statistischen Auswertung eine Aussagewahrscheinlichkeit zuweisen zu können, wird ein Bootstrap-Verfahren [7] angewendet, welches auf dem Vorgehen in [11] basiert. Das Bootstrap-Verfahren ermöglicht dank des wiederholten Ziehens von Bootstrap-Stichproben der aus der Simulation erhaltenen Ausfalldaten die Streuung der Zuverlässigkeit zur geforderten Lebensdauer zu berechnen. Diese Streuung erlaubt wiederum eine Zuverlässigkeitsaussage mit Aussagewahrscheinlichkeit und kann beispielsweise durch eine Betaverteilung [18] als Confidence Distribution [13], [14] gefasst werden, was den Zusammenhang zwischen Zuverlässigkeit und Aussagewahrscheinlichkeit für die jeweilige Lebensdauer beschreibt.

Bei herkömmlichen Bootstrap-Verfahren werden Bootstrap-Stichproben aus der Ursprungsstichprobe entsprechend deren Stichprobengröße gezogen. Da der Lebensdauersimulation der Hochvolt-Batterie jedoch zwei Stichprobengrößen zugrunde liegen, nämlich die Stichprobe der Zellmessungen ( $n_1 = 8$ ) zur Parametrisierung des Degradationsmodells (Belastbarkeitsstreuung) und die Stichprobe aus den Feldmessungen ( $n_2 = 21.000$ ) zur Bestimmung des Lastkollektivs (Belastungsstreuung), bedarf es dies in der Erzeugung der Bootstrap-Stichproben zu berücksichtigen. Aus diesem Grund wird ein doppeltes Bootstrap-Verfahren angewandt. Da die Iterationszahl sehr hoch gewählt wird ( $MC \geq 10.000$ ), können die resultierenden Iterationsschleifen der beiden Stichprobengrößen zu einer Schleife zusammengefasst werden.

Das Vorgehen, um die Zuverlässigkeitsverteilung aus den Ergebnissen der Degradationssimulation zu gewinnen ist in Bild 3 zu sehen.



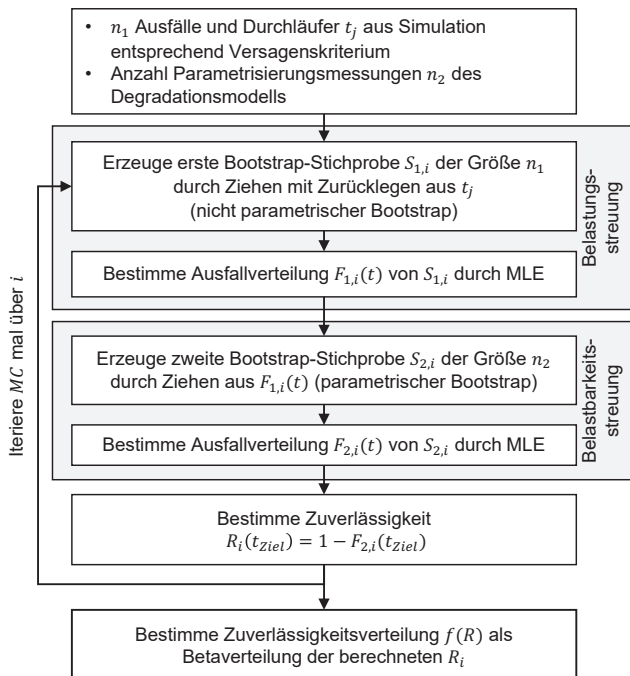


Bild 3: Vorgehen des doppelten Bootstrap-Verfahrens, um die Zuverlässigkeitsverteilung für die Ziel-Lebensdauer aus den Simulationsergebnissen zu berechnen.

Die berechneten Weibullverteilungen und zugehörige Betaverteilung für das Lebensdauerziel  $t_{Ziel} = 470 \text{ MWh}$  sind in Bild 4 zu sehen. Durch das durchgeführte Bootstrap-Verfahren, ergibt sich, dass für die geforderte Zuverlässigkeit von 90 % lediglich eine Aussagewahrscheinlichkeit von 80,46 % erreicht werden kann. Es muss also durch Erprobungsmaßnahmen diese Aussagewahrscheinlichkeit erhöht und zudem die Zuverlässigkeitsaussage aus der Simulation bestätigt werden. Eine Absicherung rein auf Basis der Vorkenntnis kann in diesem Fall und auch allgemein für weitere Anwendungen ohne weitere physische Tests von den Autoren nicht empfohlen werden, da die Simulation lediglich eine Approximation darstellt. Die ermittelte Zuverlässigkeitsverteilung der Simulation ist zusammenfassend in Tabelle 2 dargestellt.

Dieses Vorgehen ermöglicht die durchgeführten Zellmessungen und Messungen an Feldfahrzeugen mittels der Degradationssimulation in den aktuellen Kontext des Fahrzeugs zu übersetzen und eine Zuverlässigkeit mit Aussagewahrscheinlichkeit zu berechnen. Diese

kann im Weiteren zum Zuverlässigkeitsnachweis in Kombination mit Erprobungsergebnissen genutzt werden.




Bild 4: Links:  $MC = 10^6$  Weibullverteilungen aus Bootstrap-Verfahren für Versagenskriterium. Rechts: Betaverteilung mit  $A = 12,09$ ,  $B = 1,21$  zur Beschreibung des Zusammenhangs der Zuverlässigkeit und Aussagewahrscheinlichkeit für das Lebensdauerziel von  $t_{Ziel} = 470\text{ MWh}$ .

Tabelle 2 Zuverlässigkeitsaussage aus der Simulation mit Aussagewahrscheinlichkeit, welche durch das Bootstrap-Verfahren gewonnen wird.

Parameter der Betaverteilung	Zuverlässigkeitsaussage der Simulation
$A = 12,09$ $B = 1,21$	$R(t_{Ziel} = 470\text{ MWh}) = 90\text{ \%}$ bei $P_A = 80,46\text{ \%}$

**5 Zuverlässigkeitsabsicherung durch Berücksichtigung von Simulations- und Erprobungsergebnissen**

Zur Absicherung der Zuverlässigkeit der Hochvolt-Batterie bedarf es physischer Lebensdauer-Tests. Diese können dabei beispielsweise aus Prüfstandsversuchen und Fahrzeug-Dauerläufen bestehen. Handelt es sich bei den Tests um ausfallfreie Tests (auch Success-Run Tests genannt), so werden diese mit Hilfe der Binomialverteilung ausgewertet [1]. Aufgrund der Formulierung des Lebensdauerziels als kumulierter Energiedurchsatz der Batterie, werden insbesondere die Dauerläufer ein Lebensdauerverhältnis [1] aufweisen, da diese aufgrund der verschiedenen Belastung unterschiedliche Energiebedarfe haben, welches es zu berücksichtigen gilt. Neben einem Lebensdauerverhältnis, können insbesondere Prüfstandsversuche durch höhere Lasten beschleunigt werden. Über das Degradationsmodell der Simulation kann zusammen mit dem bestimmten Lastkollektiv der Feldbelastung der

Raffungsfaktor  $r$  [1] bestimmt werden. Wird eine Weibullverteilung zur Beschreibung des Ausfallverhaltens gewählt, so wird zur Berücksichtigung der Lebensdauerverhältnisse und Raffungsfaktoren ein Vorwissen in Form des Formparameters  $b$  der Weibullverteilung benötigt. Dieser kann aus den Simulationsergebnissen nach einer statistischen Auswertung wie in Kapitel 3 beschrieben entnommen werden. Treten während der Versuche dennoch Ausfälle auf, so sind diese entsprechend in der Auswertung zu berücksichtigen. Dabei haben diese Ausfälle zur Folge, dass die resultierende Verteilung aufgrund der Lebensdauerverhältnisse und Raffungsfaktoren nicht weiter die Form einer Binomialverteilung annimmt. Die Zuverlässigkeitsdichte aus der Erprobung nach Art eines Success-Run Tests mit Ausfällen lässt sich damit wie folgt bestimmen:

$$f(R) = \frac{R^{\sum \left( \frac{r_i t_i}{t_{Ziel}} \right)^b} \cdot \prod_j \left( 1 - R^{\left( \frac{r_j t_j}{t_{Ziel}} \right)^b} \right)}{\int R^{\sum \left( \frac{r_i t_i}{t_{Ziel}} \right)^b} \cdot \prod_j \left( 1 - R^{\left( \frac{r_j t_j}{t_{Ziel}} \right)^b} \right) dR} \quad (1)$$

Dabei stellen  $t_i$  die kumulierten Energiedurchsätze der Prüflinge ohne Ausfall mit entsprechendem Raffungsfaktor  $r_i$  und  $t_j$  die kumulierten Energiedurchsätze der ausgefallenen Prüflinge mit zugehörigen Raffungsfaktor  $r_j$  dar. Diese Zuverlässigkeitsdichte ist aus der Binomialverteilung abgeleitet. Hat jedoch die Zuverlässigkeit  $R$  zum Argument und wird durch das Integral im Nenner normiert.

Um die Zuverlässigkeitsdichte aus der Erprobung mit der Zuverlässigkeitsdichte aus der Batteriesimulation zu kombinieren, wird der Satz von Bayes [9] verwendet. Er ermöglicht die statistische Verknüpfung von zwei Zuverlässigkeitsinformationen und lautet hier:

$$f_{post}(R) = \frac{f(x_i|R) \cdot f_{prior}(R)}{\int_0^1 f(x_i|R) \cdot f_{prior}(R) dR} \quad (2)$$

Wobei  $f_{prior}(R)$  die a-priori Dichtefunktion der Vorkenntnis über die Zuverlässigkeit darstellt. Die Ergebnisse der Versuche werden in diesem Kontext als Likelihood  $f(x_i|R)$  gefasst, also die Wahrscheinlichkeit des Eintretens der Ereignisse aus dem Versuch unter der Bedingung der a-priori Verteilung.  $f_{post}(R)$  ist die a-posteriori Dichtefunktion, welche die Informationen beider Verteilungen enthält und um die Versuchsergebnisse korrigierte Vorkenntnis verstanden werden kann.

Werden die Versuchsergebnisse entsprechend der Dichtefunktion aus Gleichung 1 formuliert und die Vorkenntnis wie beschrieben für das Lebensdauerziel als eine Betaverteilung gewonnen, ergibt sich die durch Vorkenntnis und Versuch kombinierte und präzisierte Zuverlässigkeitsverteilung der a-posteriori Dichtefunktion wie folgt:

$$f_{post}(R) = \frac{R^{\sum \left(\frac{r_i t_i}{t_s}\right)^b} \cdot \prod_j \left(1 - R \left(\frac{r_j t_j}{t_s}\right)^b\right) \cdot R^{A-1} \cdot (1-R)^{B-1}}{\int R^{\sum \left(\frac{r_i t_i}{t_s}\right)^b} \cdot \prod_j \left(1 - R \left(\frac{r_j t_j}{t_s}\right)^b\right) \cdot R^{A-1} \cdot (1-R)^{B-1} dR}$$

(3)

Dabei sind  $A$  und  $B$  die Parameter der Betaverteilung. Da es sich bei der Betaverteilung um die mit der Binomialverteilung konjugierte Verteilung handelt [15], kann für den Fall, dass keine Ausfälle während der Erprobung auftreten, die a-posteriori Dichtefunktion auch analytisch als Betafunktion mit den Betaparametern  $A_{post} = \sum \left(\frac{r_i t_i}{t_s}\right)^b + A$  und  $B_{post} = B$  berechnet werden.

6 Ergebnisse und Vergleich mit der Weibayes-Methode

Die vorgestellte Methode wird im Folgenden auf den konkreten Fall der Absicherung der Hochvolt-Batterie angewandt. Dazu werden die Randbedingungen aus Tabelle 1 und das Zuverlässigkeitsziel von  $R_{Ziel}(t_{Ziel} = 470\text{ MWh}) = 90\text{ \%}$  mit  $P_{A,Ziel} = 90\text{ \%}$  verwendet. Die durchgeführten Versuche sollen hier beispielhaft aus  $n_{ps} = 4$  Prüfstandsversuchen und  $n_{DL} = 15$  Dauerläufern bestehen und können in Tabelle 3 eingesehen werden, sie sind als ausfallfreier Test geplant. Es trat jedoch ein Ausfall während der Dauerlauferprobung auf.

Tabelle 3 Erprobungsprogramm zur Zuverlässigkeitsabsicherung der Hochvolt-Batterie

Testart	Laufleistung	Raffung	Start	Ende	Anzahl	Ausfälle
Fahrzeug Dauerlauf	470 MWh	1	01.11.2020	27.04.2021	$n_{DL} = 15$	$x = 1$ am 01.02.2021
Prüfstand	530 MWh	1,1	01.10.2020	27.04.2021	$n_{ps} = 4$	keine

Die abgesicherte Zuverlässigkeit über der Erprobungszeit ist in Bild 5 dargestellt. Dabei ist sowohl die Zuverlässigkeit sowohl mit, als auch ohne Berücksichtigung der Vorkenntnis aufgetragen. Der sprunghafte Abfall der nachgewiesenen Mindestzuverlässigkeit ist durch den Ausfall während der Erprobung begründet. Wird die Vorkenntnis verwendet, kann die geforderte Zuverlässigkeit bereits 5 Tage früher nachgewiesen werden. Zum Erprobungsende kann zudem eine um 0,83 % größere Zuverlässigkeit nachgewiesen werden. Wird statt der abgesicherten Zuverlässigkeit die abgesicherte Lebensdauer betrachtet, ergibt sich der Verlauf in Bild 6. Dabei ist zu erkennen, dass die Ziellebensdauer ebenso 5 Tage früher abgesichert ist, als für den Fall ohne Berücksichtigung der Vorkenntnis aus der Degradationssimulation. Zu Erprobungsende ist eine Lebensdauer von 485,5 MWh nachgewiesen, welche aufgrund der Berücksichtigung der Vorkenntnis um 3,6 MWh größer

ausfällt, als für den Auswertungsfall ohne Vorkenntnis. Mit Berücksichtigung der Vorkenntnis liessen sich in diesem Erprobungsprogramm 8 der Dauerläufer und einer der Prüfstandsversuche einsparen, um dennoch zu Erprobungsende die geforderte Zuverlässigkeit nachweisen zu können.




Bild 5: Abgesicherte Zuverlässigkeit der untersuchten Methoden entsprechend dem Zuverlässigkeitsziel. Rechts: Detailansicht.




Bild 6: Abgesicherte Lebensdauer der untersuchten Methoden entsprechend dem Zuverlässigkeitsziel. Rechts: Detailansicht.

Es ist zu sehen, dass die abgesicherte Zuverlässigkeit auch ohne Berücksichtigung der Vorkenntnis zu Erprobungsbeginn ungleich Null ist. Dies ist in Gleichung 1 begründet, welche

zu einer Gleichverteilung ( $f(R) = 1 \forall R$ ) wird, wenn die Laufleistungen aller Prüflinge Null betragen. Darüber hinaus deckt sich dies mit der Überlegung zu nicht-informativen Vorkenntnissen im Satz von Bayes [1].

Um die vorgestellte Methode mit dem aktuellen Stand der Technik zu vergleichen, wird die Weibayes-Methode [19] gewählt, da diese ebenso fähig ist Vorkenntnis aus Berechnungsergebnissen im Zuverlässigkeitsnachweis zu berücksichtigen (vgl. bspw. [5]). Die erweiterte Weibayes-Methode bedient sich im Grundsatz ebenso des Satz von Bayes, schätzt jedoch statt einer Zuverlässigkeitsverteilung die charakteristische Lebensdauer einer Weibullverteilung unter der Annahme, dass der Formparameter  $b$  der Weibullverteilung bekannt ist. Die Ergebnisse aus der Berechnung gehen dabei analog der Ergebnisse aus den Versuchen ein. Die folgende Gleichung stellt die Weibayes-Methode dar um die Zuverlässigkeit mit Vertrauensbereich zu schätzen [5,19]:

$$R(t_{Ziel}) = \exp\left(-\frac{\chi^2_{2x+4;P_{A,Ziel}} \cdot t_{Ziel}^b}{2 \cdot (T_{ber}^b + \sum_i t_i^b)}\right) \quad (4)$$

Dabei ist  $T_{ber}$  die berechnete charakteristische Lebensdauer aus der Simulation,  $x$  die Anzahl an Ausfällen während der Erprobung und  $\chi^2_{2x+4;P_{A,Ziel}}$  das Quantil der  $\chi^2$ -Verteilung [16] mit dem Freiheitsgrad  $2x + 4$  zur geforderten Aussagewahrscheinlichkeit  $P_{A,Ziel}$ .

Die Ergebnisse bei Anwendung der Weibayes-Methode sind ebenfalls in den Bildern 5 und 6 zu sehen. Dabei ist zu erkennen, dass sowohl die abgesicherte Zuverlässigkeit, als auch die abgesicherte Lebensdauer kleiner sind, als aus dem erarbeiteten Verfahren mit Bootstrap. Dies ist durch die reduzierte Verwendung der Vorkenntnis begründet. Zu Erprobungsende resultiert sogar eine kleinere Zuverlässigkeit und eine kleinere abgesicherte Laufleistung, als komplett ohne Vorkenntnis. Dies ist ebenso in der einfacheren Berücksichtigung der Vorkenntnis über die charakteristische Lebensdauer begründet, welche mit medianer Aussagewahrscheinlichkeit eingeht.

## 7 Zusammenfassung und Fazit

Das hier vorgestellte Vorgehen ermöglicht es Simulationsergebnissen eine Zuverlässigkeitsaussage mit Aussagewahrscheinlichkeit zuzuordnen und diese in der Zuverlässigkeitsabsicherung zu verwenden. Es kann beispielsweise ein schnellerer Nachweis erbracht, eine höhere Zuverlässigkeit nachgewiesen, oder Prüflinge eingespart werden. Dies wird ermöglicht, indem die der Simulation zugrundeliegenden Unsicherheiten über die vorhandenen Stichprobengrößen gefasst werden und mittels einem doppelten Bootstrap-Ansatz in die Aussagewahrscheinlichkeit der Zuverlässigkeitsaussage übersetzt wird.

Die Untersuchungen anhand der Hochvolt-Batterie zeigen, dass die entwickelte Methode den gewünschten Effekt einer effizienten Zuverlässigkeitsabsicherung erzielt.

Grundsätzlich lässt sich das Vorgehen auf andere Anwendungen erweitern und stellt damit eine gute Ausgangsbasis zur Aufbereitung und Berücksichtigung von Vorkenntnissen im Zuverlässigkeitsnachweis dar.

Da die Feldmessungen hier von einem Vorgängerprodukt stammen und insbesondere die Prüfstandsversuche Abstraktionen bezüglich der Umgebungsabbildungen vornehmen, könnte in weiteren Untersuchungen die Anwendbarkeit der Informationen beispielsweise über einen Transformationsfaktor [2], [17] berücksichtigt werden. Ein solcher Transformationsfaktor sollte dabei erwartungstreu sein. Die Informationen also lediglich abschwächen, jedoch nicht verfälschen.

- [1] BERTSCHE, BERND ; LECHNER, GISEBERT: *Zuverlässigkeit im Fahrzeug- und Maschinenbau*, 2004 — ISBN 3540208712
- [2] KROLO, ANNA: Planung von Zuverlässigkeitstests mit weitreichender Berücksichtigung von Vorkenntnissen, Universität Stuttgart, 2004
- [3] BEYER, RICHARD ; LAUSTER, EUGEN: Statistische Lebensdauerprüfpläne bei Berücksichtigung von Vorkenntnissen. In: *Qualität und Zuverlässigkeit*, 35, Heft 2 (1990)
- [4] GRUNDLER, A. ; BARTHOLDT, M. ; BERTSCHE, B.: Statistical test planning using prior knowledge—advancing the approach of Beyer and Lauster. In: *Safety and Reliability – Safe Societies in a Changing World. Proceedings of ESREL 2018*. Trondheim, 2018, S. 809–814
- [5] ROMER, ACHIM: Anwendungsspezifischer Zuverlässigkeitsnachweis auf Basis von Lastkollektiven und Vorwissen, Universität Stuttgart, 2014
- [6] KLEYNER, ANDRE ; ELMORE, DAVID ; BOUKAI, BENZION: A Bayesian Approach to Determine Test Sample Size Requirements for Reliability Demonstration Retesting after Product Design Change. In: *Quality Engineering* Bd. 27 (2015), Nr. 3, S. 289–295 — ISBN 0898-2112
- [7] EFRON, BRADLEY ; TIBSHIRANI, ROBERT J.: *An Introduction to the Bootstrap* : Chapman & Hall / CRC Press LLC, 1998 — ISBN 0-412-04231-2
- [8] BUCKLAND, STEPHEN T.: Monte carlo methods for confidence interval estimation using the bootstrap technique. In: *Journal of Applied Statistics* Bd. 10 (1983), Nr. 2, S. 194–212

- [9] BAYES, MR. ; PRICE, MR.: An Essay Towards Solving a Problem in the Doctrine of Chances. By the Late Rev. Mr. Bayes, F. R. S. Communicated by Mr. Price, in a Letter to John Canton, A. M. F. R. S. In: *Philosophical Transactions of the Royal Society of London* Bd. 53 (1763), Nr. 0, S. 370–418 — ISBN 02607085
- [10] ROMER, ACHIM ; BERTSCHE, BERND ; KURFESS, JOSEF: Reducing Test Specimen Size for Reliability Determination by Combining Lifetime Calculation and Prior Information , as Exemplified by Hydraulic Pumps. In: *Proceedings of the 18th ISSAT International Conference on Reliability and Quality in Design*, 2012
- [11] GRUNDLER, ALEXANDER ; BOLLMANN, MARTIN ; OBERMAYR, MARTIN ; BERTSCHE, BERND: Berücksichtigung von Lebensdauerberechnungen als Vorkenntnis im Zuverlässigkeitsnachweis. In: *VDI-Fachtagung Technische Zuverlässigkeit 2019*, 2019
- [12] R.B. ABERNETHY: *The new Weibull handbook*, 2006 — ISBN 1092101101
- [13] NEYMAN, J.: Outline of a Theory of Statistical Estimation Based on the Classical Theory of Probability. In: *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* Bd. 236 (1937), Nr. 767, S. 333–380
- [14] BUCKLAND, STEPHEN T.: Monte carlo methods for confidence interval estimation using the bootstrap technique. In: *Journal of Applied Statistics* (1983)
- [15] RAIFFA, HOWARD ; SCHLAIFER, ROBERT: *Applied Statistical Decision Theory* : John Wiley & Sons, 1960
- [16] WILSON, EDWIN B. ; HILFERTY, MARGARET M.: The Distribution of Chi-square. In: *Proceedings of the National Academy of Sciences of the United States of America* Bd. 17 (1931), Nr. 12, S. 684–688
- [17] HITZIGER, TILMANN: Übertragbarkeit von Vorkenntnissen bei der Zuverlässigkeitstestplanung, Universität Stuttgart, 2007
- [18] GINI, C.: Considerazioni Sulle Probabilità Posteriori e Applicazioni al Rapporto dei Sessi Nelle Nascite Umane, Studi Economico- Giuridici della Universith de Cagliari, Anno III, 5-4, 1911
- [19] DIN EN 61649



## Effizienzsteigerung in der Erprobung durch das strategische Validieren von Annahmen

M.Sc. **Jens-Frederik Mischko**, Dr.-Ing. **Stefan Einbock**,

Robert Bosch GmbH, Schwieberdingen;

Dr.-Ing. **Rainer Wagener**,

Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF,  
Darmstadt

### Kurzfassung

Die Systemerprobungen sind in der Produktentwicklung von sicherheitsrelevanten Bauteilen ein wesentlicher Bestandteil der Freigabestrategie. Neben den wirtschaftlichen und zeitlichen Aufwänden, die zwangsläufig mit einer experimentellen Erprobung verbunden sind, ist die statistische Aussagekraft hinsichtlich ihrer Robustheit aufgrund des geringen Stichprobenumfanges zu hinterfragen, selbst wenn Proben des finalen Baustandes rechtzeitig zur Verfügung stehen.

Wird bei den Erprobungen, die geplante Versuchszeit ohne Ausfall erreicht, dann wird das Ergebnis als Durchläufer bzw. Success-Run gewertet. Das macht die statistische Bewertung umso schwieriger. Denn anstatt einer tatsächlich realisierbaren Lebensdauer, d.h. Einsatzzeit, ist nur eine Mindestaussage in Form einer Mindestzuverlässigkeit möglich. Diese ist verbunden mit einer Konfidenz. Die ermittelte Mindestzuverlässigkeit ist oftmals deutlich geringer als die reale Zuverlässigkeit. Deshalb können Reserven oder Leichtbaupotentiale nicht gehoben werden. Außerdem ist eine Extrapolation auf Zuverlässigkeitsaussagen im ppm-Bereich nur bedingt möglich.

Um diese Herausforderungen zu lösen, wird in diesem Beitrag eine Methode gezeigt, bei der in der Erprobung nicht der statistische Zuverlässigkeitsnachweis im Vordergrund steht, sondern vielmehr die Erprobung als Validierung von Annahmen angesehen wird. Das Ziel dieser Vorgehensweise ist es, den Stichprobenumfang im Rahmen der Systemerprobung deutlich zu reduzieren. Dabei soll der geringere Stichprobenumfang durch gezielte Analysen des bauteilgebundenen Werkstoffverhaltens kompensiert werden. Dazu ist es erforderlich, die Annahmen methodisch aufzuarbeiten und systematisch zu evaluieren. Dieser Ablauf wird hier im Rahmen dieser Arbeit exemplarisch vorgestellt.

### Abstract

System testing is an essential part of the release strategy in the product development of safety-relevant components. In addition to the economic and time expenses that are inevitably associated with experimental testing, the statistical significance in terms of its robustness must

be questioned due to the small sample size, even if samples in the final design phase are available in time.

If the test time is reached without a failure, the result is considered as a success run. This makes the statistical evaluation even more difficult. Instead of an exact lifetime, i.e. operating time, only a minimum statement in the form of a minimum reliability is possible. This is associated with a confidence. The determined minimum reliability is often significantly lower than the real reliability. Therefore, it is impossible to increase reserves or lightweight potentials. Furthermore, extrapolation to a reliability in the ppm range is only possible to a limited extent. To solve these challenges, this paper presents a method that does not focus on statistical reliability verification in testing, instead considering testing as a validation of assumptions. The aim of this approach is to significantly reduce the sample size in system testing. The smaller sample size is to be compensated by targeted analyses of the component-related material behavior. For this purpose, it is necessary to methodically review and systematically evaluate the assumptions. This procedure is presented as an example in this paper.

## **0. Zusammenfassung**

Über einen neuen Ansatz soll der Zuverlässigkeitsnachweis mit Hilfe von Erprobungen effizienter durchgeführt werden können. Die Effizienzsteigerung wird durch einen geringeren Stichprobenumfang erreicht und zeichnet sich durch geringere Kosten- und Zeiteinsatz aus. Dabei ist das Ziel, dass die Aussagegüte (mindestens) gleichbleibend ist.

Die Idee hinter dem Konzept ist es, dass bestehende Erprobungen analysiert und die dahinterstehenden Annahmen herausgearbeitet werden. Erforderliche Ersatzmaßnahmen haben das Ziel, die Annahmen zu bestätigen. Der Zuverlässigkeitsnachweis erfolgt dann nicht mehr hinsichtlich einer statistischen Kenngröße, sondern liegt ausschließlich beim Bestätigen der Annahmen. Als Ergebnis wurde eine Methode inkl. Kriterien für diesen Nachweis erarbeitet.

## **1. Einleitung und Motivation**

Im Rahmen der Produktentwicklung nehmen Erprobungen einen wesentlichen Bestandteil in den Freigabekonzepten von Systemen ein. Diese Maßnahmen stehen in einem Zielkonflikt:

- Nachweis eines zuverlässigen Produktes,
- Niedrige Erprobungskosten und geringe Erprobungszeiten.

Auf der einen Seite soll eine möglichst hohe Zuverlässigkeit nachgewiesen werden, um mögliche Fehler während der Produktnutzungsphase zu verhindern. Diese können z.B. zu Rückrufaktionen führen, wenn die Sicherheit der Kunden gefährdet ist oder zu einer erhöhten

Garantie- bzw. Kulanzleistungen [1]. Dementgegen stehen die meist sehr zeit- und kostenintensiven Erprobungsaufwände, die einen großen Stichprobenumfang unwirtschaftlich machen. Zudem sollten elementare Fehler auch schon zu einem frühen Zeitpunkt in der Produktentwicklung entdeckt werden, wie die sogenannte „Rule of Ten“ verdeutlicht, vgl. Bild 1. Diese gibt den exponentiellen Zusammenhang zwischen den Kosten und dem Entdecken eines Fehlers über die Zeit an. Zwischen den einzelnen Entwicklungsphasen steigen die Kosten um den Faktor 10 [2,3].

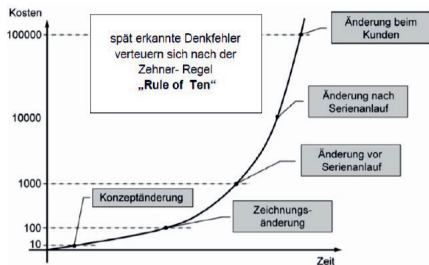


Bild 1: Rule of Ten, entnommen aus [2].

Der Zielkonflikt zum Nachweis eines zuverlässigen Produktes und geringen Erprobungskosten soll durch einen neuen Ansatz entschärft werden. Die Idee besteht darin, dass in einer Erprobung keine statistischen Kennwerte überprüft, sondern vielmehr die Annahmen, die hinter der Erprobung stehen, validiert werden. Dadurch kann ein erheblicher Teil der Kosten- und Zeitintensiven Erprobungen eingespart und damit gleichzeitig die Effizienz in der Produktentwicklung gesteigert werden. Der dadurch verringerte Stichprobenumfang soll durch eine methodische Vorgehensweise gerechtfertigt werden, sodass die Risiken, die eine solche Vorgehensweise mit sich bringen, möglichst minimiert werden.

## 2. Grundlagen und Einführungsbeispiel

Für die Beurteilung der Zuverlässigkeit mit Hilfe von Erprobungen, werden diese auf Basis der Binomialverteilung geplant. Es wird davon ausgegangen, dass zum Zeitpunkt  $t$  die Zuverlässigkeit der Prüflinge  $R_i(t)$  beträgt. Handelt es sich bei den Prüflingen über einen statistisch unabhängigen Stichprobenumfang, dann gilt für die Zuverlässigkeit eines jeden Prüflings  $R_1(t) = \dots = R_n(t) = R(t)$  [3,4]. Die Wahrscheinlichkeit, dass bis zum Zeitpunkt  $t$  kein Prüfling ausfällt, kann durch die Multiplikation der Zuverlässigkeit der einzelnen Prüflinge berechnet werden und beträgt  $R(t)^n$ . Dabei ist  $n$  die Anzahl der geprüften Stichproben. Aus der umgekehrten Formulierung, dass alle  $n$  Stichproben bis zum Zeitpunkt  $t$  überleben, lässt

sich die Wahrscheinlichkeit eines Ausfalls bis zu diesem Zeitpunkt formulieren. Daraus lässt sich die Aussagewahrscheinlichkeit bzw. die Konfidenz  $C$  berechnen:

$$C = 1 - R^n.$$

Aus diesem Zusammenhang heraus, kann der Stichprobenumfang definiert werden, der mindestens für den Nachweis der Zuverlässigkeit notwendig ist. Da es sich bei dieser Vorgehensweise um eine Erprobung handelt, bei der mit keinem Ausfall des Prüflings gerechnet wird, ist von einem sogenannten „Success-Run“ die Rede. Fallen während der Erprobung wenige Stichproben aus, dann können die Kenngrößen mit Hilfe der Binomialverteilung berechnet werden [3,5,6].

Der Nachweis der Zuverlässigkeit über eine Erprobung durch Success-Runs ist mit einem sehr großen Aufwand verbunden. Soll beispielsweise die Zuverlässigkeit von  $R = 90\%$  mit einer Konfidenz von  $C = 95\%$  nachgewiesen werden, dann ist dies mit einem Stichprobenumfang von  $n = 29$  Teilen möglich. Ein solcher Stichprobenumfang ist aus wirtschaftlichen Gründen meist nicht zu realisieren. Weitere Nachteile eines solchen Zuverlässigkeitsnachweises sind:

- Lange Versuchszeiten,
- Hohe Versuchskosten,
- Geringe statistische Aussagekraft,
- Nachweis einer Mindestlebensdauer.

### 3. Zuverlässigkeitskonzept

Im Rahmen dieses Beitrages soll ein Konzept vorgestellt werden, dass dazu beitragen soll, den Zuverlässigkeitsnachweis effektiver zu gestalten. Dazu soll der Erprobungsaufwand deutlich reduziert werden. Es soll die folgende Idee umgesetzt werden:

- Es sollen auch weiterhin möglich Erprobungen durchzuführen,
- Dabei sollen im Rahmen der Erprobung lediglich die Annahmen überprüft werden.

Zunächst ist ein Einsatz dieser Methode bei der Überprüfung von Qualitätszielen während der Fertigung geplant. Dies hat den Vorteil, dass eine Zuverlässigkeitsfreigaben auf Plattformebene bereits stattgefunden hat.

Im Bild 2 ist schematisch die grundsätzliche Idee der Methodik dargestellt. In der Realität gibt es verschiedene Lasten, die einen Einfluss auf die Lebensdauer und damit die Zuverlässigkeit des Systems haben. Mit Prüfsystemen wird versucht, diese Lasten zu simulieren. Wie im vorangegangenen Abschnitt beschrieben, wird durch einen großen Stichprobenumfang und mit Hilfe von Erprobungen die Zuverlässigkeit nachgewiesen (blauer Pfad). Die grundsätzliche Idee anhand der Designelemente und anhand der Schadensmechanismen (SM) mit Hilfe von Lebensdauermodellen die Zuverlässigkeit nachzuweisen und zu gestalten ist bereits Stand




Bild 2: Möglichkeiten zum Nachweis der Zuverlässigkeit

der Technik. Wird dieser Weg jedoch exklusiv betrachtet, dann kann es vorkommen, dass z.B. Wirkzusammenhänge oder Wechselwirkungen übersehen werden. Deshalb sollen die Annahmen, die in der Erprobung implizit oder explizit getroffen werden, für den Zuverlässigkeitsnachweis nochmals herausgearbeitet werden. Der Nachweis der Zuverlässigkeit erfolgt durch das Bestätigen der Annahmen (grauer Pfad). Eine gleichbleibende Aussagegüte der beiden Wege soll durch einen qualitativen Vergleich sichergestellt werden.

Um das zu erreichen, wurde ein Konzept entwickelt, das sich in vier Hauptschritte aufteilt, die auch in Bild 3 dargestellt sind.

- Erprobungs- und Systemanalyse,
- Einflussanalyse,
- Bewertung der Ersatzmaßnahmen,
- Finale Risikobewertung.



Bild 3: Die Schritte bei der Bewertung der Erprobung

*Mit Hilfe der Methode wird angenommen, dass eine vorhandene Erprobung ersetzt werden kann. Zur besseren Veranschaulichung der Methode soll ein Beispiel erläutert werden, das*

*stark vereinfacht dargestellt ist. Während der Fertigung sollen kontinuierlich die Qualitätsziele einer Getriebewellen überprüft werden. Dies wird durch eine Erprobung sichergestellt, bei der die Getriebewelle wechselnden Lasten ausgesetzt ist. Die Erprobung erfolgt mit insgesamt sechs Teilen und zielt auf einen Success-Run ab. Die wichtigste Kenngröße, gegen die abgesichert werden soll, ist die Dauerfestigkeit. Aus wirtschaftlichen Gründen wird das Rechteck-Auslegungskollektiv transformiert zu einem Kollektiv mit höheren Lasten. Jedoch ist die Anzahl der Zyklen aus wirtschaftlichen Gründen auf  $N = 50.000$  Schwingspiele begrenzt. Eine weitere Erhöhung der Last ist aus technischen Gründen nicht möglich.*

### Analyse des Systems, das bei der Erprobung geprüft wird

Im ersten Schritt werden die Erprobung und das dazugehörige System analysiert und bewertet. Dazu werden zunächst die explizit und implizit getroffenen Annahmen herausgefunden und anschließend systematisch bewertet. Die Annahmen sind die Einflussgrößen, die in der Erprobung die Zuverlässigkeit beeinflussen können. Das Ziel der Bewertung ist es, die getroffenen Annahmen und deren Abdeckung in der Erprobung zu bewerten. Die Analyse der Annahmen für die Erprobung kann im Wesentlichen in die beiden Teilaspekte aufgeteilt werden:

- Annahmen bezüglich der Beanspruchbarkeit
- Annahmen bezogen auf die Beanspruchung

Liegt beispielsweise für die Beanspruchbarkeit ein Lebensdauermodell vor, so können die Parameter des Lebensdauermodells schon ein wesentlicher Bestandteil der getroffenen Annahmen für die Beanspruchbarkeit sein. Diese Annahmen werden dann zum Teil noch

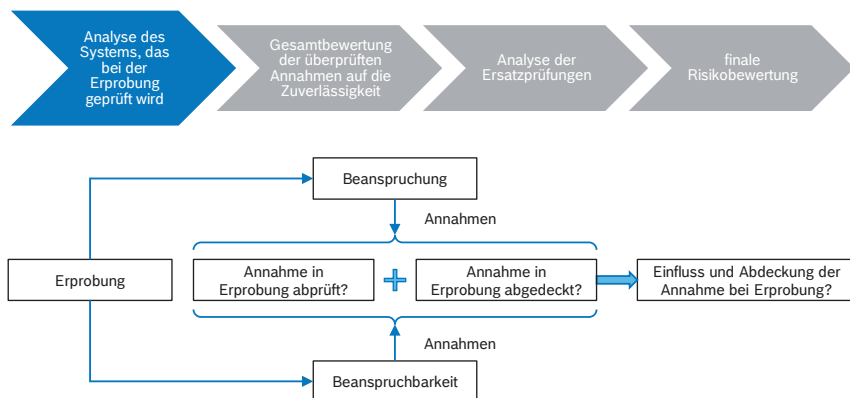


Bild 4: Analyse des Systems

ergänzt durch weitere Einflüsse auf das Lebensdauermodell. Es sind auch weitere Übertragungsfaktoren oder -funktionen zu berücksichtigen, die von einer einfachen Ersatzmaßnahme auf eine komplexere Systemprüfung zu berücksichtigen sind. Als Annahme der Beanspruchbarkeit können auch physikalische Modelle zur Hilfe genommen werden und die dortigen Parameter in der Erprobung überprüft werden.

Bei der Beanspruchung sollen die Lasten, die in der Erprobung auf das System gebracht werden, herausgefunden werden. Als Erweiterung der Beanspruchung zählen auch Lasten, die sich z.B. durch die Kollektivform ergeben. Weiter können auch Alterungs- oder Korrosionseffekte einen Einfluss auf die Beanspruchung haben. Die genannten Beanspruchungen entstehen vor allem aus Lasten, die von außen aufgetragen werden. Es können aber auch Lasten innerhalb des Systems entstehen.

Die Bewertung dieser Annahmen erfolgt dann im Hinblick auf die untersuchte Erprobung anhand der folgenden beiden Kriterien:

- Sollen die Annahmen in der untersuchten Erprobung werden?
- Wie gut wird der Einfluss der Annahme in der Erprobung?

Die erste Bewertung zielt darauf ab, ob in der Erprobung die jeweiligen Annahmen überprüft werden sollen, da nicht immer jede der Annahmen auch in der Erprobung überprüft werden.

Im zweiten Teil soll dann der Einfluss der Annahme bei der Erprobung  $E$  bewertet werden. Dieser wird mit einer skalaren Bewertung zwischen 1 und 5 durchgeführt. Der Wert 1 steht für einen sehr großen und direkt nachweisbaren Einfluss. Bei einer Bewertung von 5 kann kein Einfluss der Annahme festgestellt werden. Als Hilfestellung können die folgenden Fragen verwendet werden:

- Wie groß ist der Stichprobenumfang?
- Handelt es sich bei dem Versuch um einen Success-Run?
- Kann ein Einfluss der Annahme zweifelsfrei festgestellt werden?

*Für die Erprobung der Getriebewelle kann auf der Seite der Beanspruchbarkeit vor allem die Parameter der Wöhlerlinie als Annahme angesehen werden (Neigung, mittlere Dauerfestigkeit, Eckschwingenspielzahl und Streuung). Weitere Parameter, die einen Einfluss auf die Schwingfestigkeit haben, sind z.B. der Mittelspannungseinfluss, die Kerbwirkung oder die Stützwirkung. Auf der Seite der Beanspruchung kann als Annahme beispielsweise die richtige Lasteinleitung oder die richtig angenommenen Wechselwirkungen genannt werden. Für dieses Beispiel werden Annahmen herausgenommen. Dazu werden die mittlere Dauerfestigkeit und die Kerbwirkung gewählt.*

*Der Einfluss der Dauerfestigkeit wird mit dem Wert  $E = 2$  bewertet. In der Erprobung können diese Annahme nur bedingt nachgewiesen werden, da es sich um eine geraffte Erprobung*

*handelt, mit dem Ziel eines Success-Runs. Dennoch können große Abweichungen, insbesondere eine Verschlechterung, der Dauerfestigkeit nachgewiesen werden.*

*Die Kerbwirkung, die auch die Dauerfestigkeit beeinflusst, kann hingegen mit der vorgesehenen Erprobung nicht überprüft werden. Tritt eine signifikante Verbesserung oder Verschlechterung dieser Annahme in der Serie ein, dann kann dies nur über andere Maßnahmen ermittelt werden. Deshalb wird dieser Einfluss mit dem Wert  $E = 5$  bewertet.*

### **Einfluss der Annahmen bewerten**

Im zweiten Schritt werden die einzelnen Annahmen hinsichtlich ihres Einflusses auf die Zuverlässigkeit bewertet. Die Bewertungen können sich in diesem Schritt ändern, abhängig vom Ziel der untersuchten Erprobung. Dazu kann z.B. zählen:

- Der Überprüfung von Qualitätszielen in der Fertigung,
- Änderung oder Freigabe weiterer Zulieferer,
- Änderungen am Design.

In diesem Schritt sollen, wie in Bild 5 dargestellt, zwei Bewertungen für die Annahmen durchgeführt werden:

- Ist eine Änderung der Annahme zu erwarten?
- Wie wird der Einfluss auf die Zuverlässigkeit eingeschätzt?

Mit dem ersten Faktor  $B_1$ , wird bewertet ob, eine Änderung der Annahme zu erwarten ist. Dabei kann sich die konkrete Fragestellung abhängig von der untersuchten Erprobung unterscheiden. Bei einer Erprobung, mit der die Qualitätsziele in der Fertigung abgesichert werden, wird eine Änderung der Annahme während der Serie überprüft. Für eine Bewertung des Faktors mit dem Wert 1 ist keine Änderung der Annahme zu erwarten. Bei einer Bewertung mit dem Wert 5 ist dagegen mit einer sehr deutlichen Änderung zu rechnen. Dieser Faktor kann über Expertenwissen abgeschätzt werden. Am Beispiel der Überprüfung der Qualitätsziele können folgende Fragestellungen bei der Beurteilung unterstützen:

- Ist mit einem Verschleiß des Fertigungswerkzeuges zu rechnen?
- Wie groß ist der Verschleiß vom Neuzustand bis zum Wechsel des Fertigungswerkzeuges?
- An welchen Stellen tritt der Verschleiß vorwiegend auf? Haben diese einen Einfluss auf die Annahme?
- Wie stabil sind die Prozessparameter?

Mit dem Faktor  $B_2$  wird der Einfluss der Annahme auf die Zuverlässigkeit abgeschätzt. Ist kein Einfluss auf die Zuverlässigkeit vorhanden, dann wird dieser Faktor mit dem Wert 1 bewertet. Der Wert 5 gibt einen sehr großen Einfluss dieser Annahme auf die Zuverlässigkeit an. Eine



Abschätzung des Faktors  $B_2$  kann z.B. über Parametervariationen bei Lebensdauermodellen und das Hinzuziehen von Expertenwissen erfolgen.

Die beiden Faktoren  $B_1$  und  $B_2$  können mit Hilfe der Gleichung g1 zu dem Bewertungskriterium  $B$  der Annahme zusammengeführt werden.

$$B = \lceil \sqrt{B_1 \cdot B_2} \rceil$$

Das Bewertungskriteriums  $B$  kann den drei Kategorien zu geordnet werden:

- Falls  $B < 3$  ist, dann wird keine Ersatzmaßnahme empfohlen
- Für  $B = 3$  wird keine eindeutige Empfehlung für eine Ersatzmaßnahme ausgesprochen
- Ist der Wert  $B > 3$ , dann wird eine Ersatzmaßnahme empfohlen

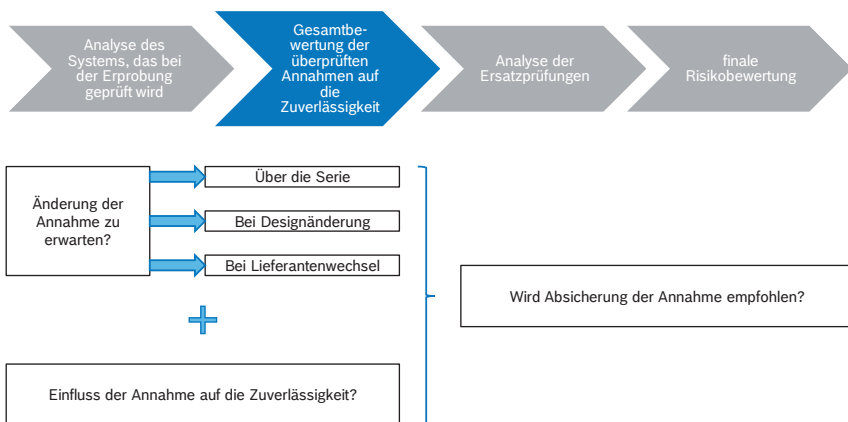


Bild 5: Bewertung des Einflusses der einzelnen Annahmen

Für die beiden beschriebenen Annahmen wird nun eine Bewertung der Einflüsse durchgeführt. Die Dauerfestigkeit wird mit dem Faktor  $B_1 = 3$  bewertet. Diese durchschnittliche Bewertung folgt aufgrund der Einschätzung, dass sich die Dauerfestigkeit im Verlauf der Serie durchaus ändern kann. Als Grund dafür kann z.B. der Einfluss der Wärmebehandlung auf die Dauerfestigkeit genannt werden. Ein Einfluss der Dauerfestigkeit auf die Zuverlässigkeit ist signifikant. Eine niedrigere Dauerfestigkeit resultiert in einer niedrigeren Zuverlässigkeit. Deshalb wird für  $B_2 = 5$  gewählt. Demnach ergibt sich für die Gesamtbewertung des Einflusses der Annahme  $B = \lceil \sqrt{3 \cdot 5} \rceil = 4$ . Eine Ersatzmaßnahme wird also empfohlen.

Eine Änderung der Kerbwirkung während der Serienproduktion wird dagegen mit dem Faktor  $B_1 = 1$  bewertet, da eine Änderung der Kerbwirkungszahl bei stabilen Fertigungsprozessen nahezu ausgeschlossen ist. Der Einfluss auf die Zuverlässigkeit ist in einem mittleren Bereich

einzuordnen und wird mit  $B_2 = 3$  bewertet. Als Gesamtbewertung folgt dann der Wert:  $B = \lceil \sqrt{1 \cdot 3} \rceil = 2$ . Für diese Annahme wird folglich keine Ersatzmaßnahme empfohlen.

### Analyse der Ersatzmaßnahme

Die Analyse der Ersatzmaßnahme erfolgt anhand der folgenden Kriterien:

- Wird die Annahme in der Ersatzmaßnahme überprüft?
- Wie gut kann der Einfluss der Annahme ermittelt werden?
- Ist eine Übertragbarkeit der Annahme auf die Erprobung bzw. das System zulässig?

Dieser Schritt soll einen Vergleich mit der Erprobung ermöglichen und einen möglicherweise reduzierten Stichprobenumfang rechtfertigen. Der Ablauf ist in Bild 6 dargestellt.

Zunächst wird bewertet, ob mit der Ersatzmaßnahme die Annahme validiert werden. Eine einzelne Ersatzmaßnahme kann selten die kompletten Annahmen der ursprünglichen Erprobung abdecken. Es sind somit ggf. weitere Ersatzmaßnahmen zu definieren.

Wird die Annahme in der Ersatzmaßnahme abgedeckt, so werden diese durch zwei Faktoren bewertet

- Wie gut kann die Annahme in der Ersatzmaßnahme ermittelt werden?
- Wie ist die Übertragbarkeit der Annahme auf die Erprobung?

Zunächst soll bewertet werden, wie gut die Annahme durch die Ersatzmaßnahme abgedeckt ist. Kann die Annahme sehr gut ermittelt werden, so ist dieser Faktor  $M_1$  mit dem Wert 1 zu bewerten. Bei einer ungenauen Abdeckung der Annahme mit der Ersatzmaßnahme ist eine Bewertung von 5 vorzunehmen. Um diesen Faktor zu bewerten, ist insbesondere auch ein Vergleich mit der Erprobung durchzuführen. Einen Einfluss hat u.a. der Stichprobenumfang, die Anzahl der Lastniveaus oder die Genauigkeit der Ergebnisse.

Ein weiterer wichtiger Baustein bei der Bewertung ist die Übertragbarkeit der Ersatzmaßnahme auf eine Systemprüfung. Nur wenn zuverlässig festgestellt werden kann, dass eine Übertragbarkeit gegeben ist, kann der Ersatzversuch auch die Erprobung ersetzen. Wieder ist eine Bewertung  $M_2$  zwischen den Werten 1 und 5 vorgesehen, wobei der Wert 1 eine sehr gute Übertragbarkeit und der Wert 5 keine Übertragbarkeit der Annahme aussagt. Aus der Kombination dieser beiden Bewertungszahlen soll eine Risikoabschätzung der Ersatzmaßnahme stattfinden. Diese erfolgt über:

$$M = \lceil \sqrt{M_1 \cdot M_2} \rceil$$

- Bei einer Bewertung von  $M < 3$  ist kein besonderes Risiko der Annahme durch die Ersatzmaßnahme zu erwarten.

- Eine Bewertung von  $M > 3$  sollte nochmal überarbeitet werden, sodass dieses Risiko weiter sinkt. Es ist sonst als alleinige Maßnahme nicht zu empfehlen.

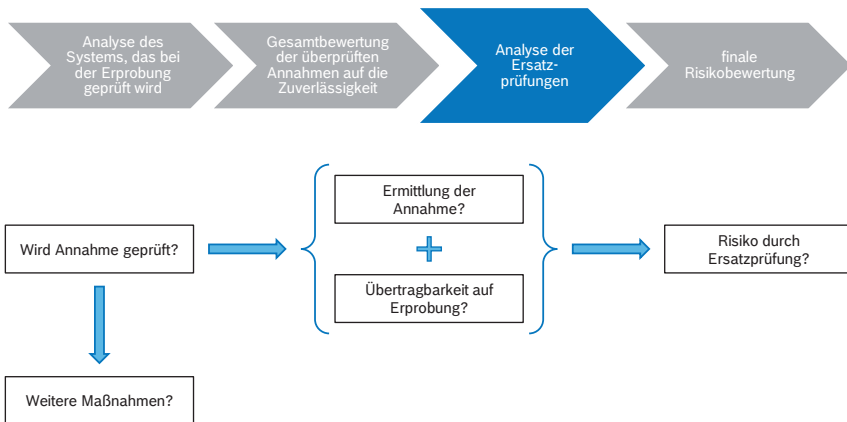


Bild 6: Bewertung der möglichen Ersatzmaßnahmen

Als Ersatzmaßnahme für die Ermittlung der Dauerfestigkeit wird eine Härtemessung angestrebt. Dies ist eine einfache, aber dennoch geeignete Methode, um eine Abschätzung der Dauerfestigkeit durchzuführen. Dabei kann auch ein deutlich größerer Stichprobenumfang bei geringeren Kosten durchgeführt werden. Demnach werden die Faktoren mit  $M_1 = 3$  und  $M_2 = 3$  bewertet. Als Analyse der Ersatzprüfung folgt der Wert  $M = \lceil \sqrt{3 \cdot 3} \rceil = 3$ .

Auf eine Ersatzmaßnahme für die Beurteilung der Kerbwirkung wird in diesem Fall verzichtet, da bei der vorangegangenen Bewertung keine empfohlen wurde.

## Finale Bewertung

Im letzten Schritt sollen die Annahmen und die abgeleiteten Maßnahmen einer Gesamtbewertung unterzogen werden. Hierbei werden die Faktoren der Einzelbewertungen gegenübergestellt und miteinander verglichen. Dieser Vergleich soll dabei unterstützen eine Entscheidung herbeizuführen bezüglich der Entscheidung ob die getroffenen Maßnahmen, die Reduktion des Stichprobenumfangs einer Erprobung rechtfertigen. Die gesamte Vorgehensweise ist schematisch im Bild 7 gezeigt. Die Bewertung erfolgt im Einzelnen:

- Vergleich aus den Fragestellungen: Wird die Annahme in der Erprobung überprüft? Wird eine Absicherung der Annahme empfohlen? Wird die Annahme in der Ersatzmaßnahme abgedeckt?

- Vergleich zwischen der Abdeckung der Annahme in der Erprobung und der Bewertung des Risikos durch eine Ersatzmaßnahme.

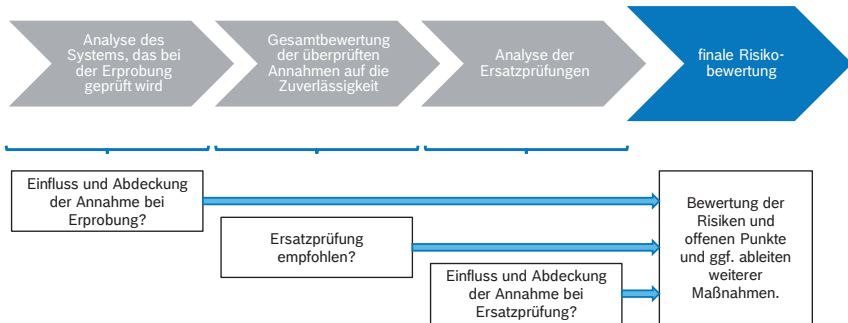


Bild 7: Gesamtbewertung der Erprobung und deren Annahmen

*Für die finale Bewertung werden die in den vorangegangenen Schritten ermittelten Faktoren gegenübergestellt und miteinander verglichen. Dabei schneidet die Ersatzmaßnahme in der Bewertung deutlich besser ab als die ursprüngliche Erprobung. Für eine vollständige Bewertung müssen alle Annahmen mitberücksichtigt werden. Zudem sind in der finalen Bewertung die Einsparungen bezüglich der Kosten und der Zeit mitaufzuführen. Für die Umsetzung der Maßnahmen sollte sich bei der Zeit und den Kosten ein deutlicher Vorteil ergeben.*

## 5. Ausblick

Im weiteren Schritt soll für die Methodik ein geeignetes Tool bereitgestellt werden. Das beinhaltet eine weitere Ausarbeitung der einzelnen Bewertungskriterien und die Berücksichtigung der weiteren Faktoren Kosten und Zeit bei der finalen Bewertung der Ersatzmaßnahmen im Vergleich zur Erprobung. Anschließend ist geplant diese Methode durchgängig an einem geeigneten Beispiel anzuwenden.

## 6. Literaturangaben

- [1] Ungermann, J.: Zuverlässigkeitsnachweis und Zuverlässigkeitsentwicklung in der Gesamtfahrzeugerprobung. Dissertation ETH Zürich 2009.
- [2] Albers, A.; Behrendt, M.; Klingler, S.; Matros, K.: Verifikation und Validierung im Produktentstehungsprozess. Handbuch Produktentstehung (2016) S. 541-569.
- [3] Bertsche, B.; Lechner, G. Zuverlässigkeit im Fahrzeug- und Maschinenbau. 3. Auflage, Springer Verlag, Berlin, Heidelberg, New York, 2004.

- [4] Verband der Automobilindustrie e.V. (VDA): Qualitätsmanagement in der Automobilindustrie: Zuverlässigkeitssicherung bei Automobilherstellern und Lieferanten. Teil 2, 4.Auflage, Frankfurt: VDA-QMC, 2016.
- [5] Meyna, A.; Pauli, B.: Taschenbuch der Zuverlässigkeitstechnik: Quantitative Bewertungsverfahren. 2. Auflage, Hanser Verlag, München, Wien, 2010.
- [6] Birolini, A.; Reliability Engineering: Theory and Practice. 8. Auflage, Springer Verlag, Berlin, Heidelberg, New York, 2017.



# **Safety-Management für mechatronische Systeme: Ein elementarer Baustein in der Produktentwicklung am Beispiel der Marineteknik**

## **Safety management for mechatronic systems: An essential element in product development using marine technology as an example**

**Dr.-Ing. J. Isermann, Dr.-Ing. H. Neuhaus, Dipl.-Inf. (FH) C. Blank,  
E. Yücel, M.Sc., ATLAS ELEKTRONIK GmbH, Bremen**

### **Kurzfassung**

Der Beitrag beschreibt wesentliche Züge zu den theoretischen Grundlagen und praktischen Ansätzen des Safety-Managements in der technischen Produktentwicklung. Der Fokus liegt hier auf mechatronischen Systemen mit im Marinebereich herausfordernden Produkteigenschaften, die durch einen zunehmend höheren Anteil von beteiligter Software ein systematisches und ganzheitliches Safety-Management erfordern. Vorgestellt werden wichtige Einflussgrößen wie die Safety-Culture, der gezielte Einsatz einschlägiger Normen, eine auf Safety justierte innerbetriebliche Prozesskette und kommerzielle Aspekte des Safety-Managements.

### **Abstract**

The article describes essential features of the theoretical background and practical approaches to safety management in technical product development. The focus is on the use of a mechatronic system with challenging product characteristics in the naval sector, which requires a systematic and holistic safety management due to an increasingly high proportion of software involved. Important influencing factors such as the safety culture, the targeted use of relevant standards, and an internal process chain adjusted to safety and commercial aspects of safety management are presented.

### **1. Motivation**

Die Sicherheit stellt ein wesentliches Grundbedürfnis des Menschen dar. Der „Safety“-Begriff charakterisiert einen Zustand, der frei von unakzeptablen Risiken ist. Das Risiko ist definiert als das Produkt aus Eintrittswahrscheinlichkeit eines Schadens und der Schadensauswirkung. Ein vornehmliches Ziel des Safety-Managements ist es, im Rahmen der Produktentwicklungstätigkeiten diese beiden Einflussfaktoren in Bezug auf ihren Wertebereich

zu minimieren. Dazu wird als ein Element das Risiko auf Systemebene bewertet sowie Mitigationsmaßnahmen ermittelt und in die Umsetzung gebracht um ein akzeptables Risikomaß zu erhalten. Mit diesem Betrachtungsfokus auf Systemebene stellt das Safety-Management mit den assoziierten Tätigkeiten des Safety-Engineerings damit eine Fachdisziplin des generischen Systems Engineering dar [1]. Dieser transdisziplinäre Ansatz kann in diesem Übersichtsbeitrag nur einen ersten Eindruck dessen leisten, was an Hintergrundwissen notwendig ist, um zweckmäßiges und fachlich korrektes Safety-Management praktizieren zu können. Der Aufsatz behandelt die Inhalte vor dem Hintergrund des Praxisbezugs zur Marinetechnik. Die Branche hat in diesem Zusammenhang die besondere Herausforderung, dass die Systeme einerseits in der Regel einen hohen technischen Komplexitätsgrad aufweisen, und andererseits aufgrund ihrer funktionalen Anforderungen, die aus ihren Aufgaben resultieren, gelegentlich ein hohes Restrisiko bei der Nutzung aufweisen.

Insbesondere für Produkte mit sicherheitskritischen Funktionen ist es von Bedeutung, für die funktionale Sicherheit des Systems Sorge zu tragen, um Menschen, die Umwelt und das System selbst vor Unfällen bzw. Schäden zu bewahren. Es besteht somit ein ureigenes Interesse auf Seiten der Hersteller, den gesetzlichen und vertraglichen Anforderungen zu genügen. Darüber hinaus stellt ein im Ergebnis funktionierendes Safety-Management ein herausstechendes Merkmal am Markt dar. Daraus resultiert ein entsprechendes Interesse an einem praktikablen und fachlich anerkannten Prozess, der letztlich zum Nachweis eines sicheren Produktes führen muss.

## **2. Notwendigkeit der Safety- und Zuverlässigkeitstechnik in der Produktentwicklung**

Fehlfunktionen, Ausfälle oder Störungen können in technischen Systemen zu schweren Unfällen führen. Die Gründe für das Auftreten dieser Unfallursachen können nach [2] in einer mangelhaften Entwicklung, einer kläglichen Fertigung, inadäquatem Testen, menschlichem Versagen, einer schlechten Wartung, einer unsachgemäßen Verwendung oder fehlendem Schutz vor übermäßiger Belastung gesehen werden. In der Produktentwicklung ist daher ein systematischer Prozess notwendig, der das Auftreten und die Wiederholung von Fehlern minimiert und ein Verständnis dafür schafft, weshalb und wie Fehler geschehen. [2]

Die Aspekte der Zuverlässigkeitstechnik ergänzen hierbei das Safety-Management: Während sich die Zuverlässigkeitstechnik mit Ausfallkonzepten beschäftigt, befasst sich „Safety“ mit den Konsequenzen eines Fehlers, der sich negativ auf die Umgebung auswirkt. Dabei kann eine inhärent sichere Konstruktion die Auswirkungen eines Fehlers minimieren. Die Zuverlässigkeits- und Sicherheitstechnik versucht, in der Praxis häufig symbiotisch, ein



quantitatives Maß für die Leistung von Systemen zu liefern, identifiziert die wesentlichen Akteure und ermittelt ein Verständnis zur Steigerung der Systemleistung um im Ergebnis bei den Systemen eine verringerte Wahrscheinlichkeit des Auftretens von Fehlern mit riskanten Konsequenzen zu erreichen [2]. Damit wird ein wichtiger Beitrag zu zahlreichen Ingenieurdisziplinen geleistet, so auch zum Safety-Management welches im Folgenden genauer charakterisiert wird.

### **3. Wesentliche Aspekte mechatronischer Systeme, die Rolle der Software, Grad der Beherrschbarkeit**

Um mechatronische Systeme beherrschbar und in angemessenen Kosten zu entwickeln, ist die Architektur und das Design des Systems sehr wichtig. In der Architektur und dem Design wird festgelegt welche Anforderungen an das System wie umgesetzt werden. Dazu gehört auch, ob ein Aspekt mechanisch, elektrisch, elektronisch oder per Software umgesetzt wird. Grundsätzlich ist es sinnvoll, eine Umsetzung in dieser Reihenfolge zu lösen, da die Beherrschbarkeit abnimmt. Das bedeutet, mechanische Anteile sind deutlich beherrschbarer als Software. Software gilt als leicht änderbar, aber die Verifikations- und Validierungstätigkeiten werden oft unterschätzt. Dazu kommt, dass eine Software mit einem gewissen Umfang nicht fehlerfrei sein wird. Mechanische und elektrische Systeme sind weniger flexibel in der Anpassbarkeit erweisen sich in der Praxis aber als robuster.

Eine Architektur und ein Design, welches sorgfältig gewählt ist, kann für Weiterentwicklungen einen hohen Grad an Modularität, Risikominimierung und Kostensenkung zur Folge aufweisen, da nur noch dedizierte Anpassungen notwendig sind.

### **4. Systementwicklung Marinetechnik**

Die Systementwicklung in der Marinetechnik ist sehr vielseitig und technisch herausfordernd. Von klassischen Teil-/Systemen in Über- und Unterwasserbereich gibt es auch autonome Fahrzeuge, die ihre Missionen selbstständig erledigen müssen. Gerade im Unterwasserbereich kann man sich nicht mehr auf übliche Technologien, z.B. GPS, zur Positionsbestimmung verlassen und muss auf diverse Verfahren zurückgreifen und diese zusammenführen, um eine Entscheidungsgrundlage für Menschen und autonome System zu liefern. Darüber hinaus hat man es in der Marinetechnik mit vielen zwischenmenschlichen und technischen Schnittstellen zu tun, die international ausgeprägt sind. Die technischen Schnittstellen sind sowohl standardisiert als auch proprietär, was die Einbindung in ein Teil-/System immer wieder vor neue Herausforderungen stellt. Hinzu kommt, dass man im militärischen Kontext oft eine Definitionslücke vorfindet, da dieser nicht wie die zivile Welt

detailliert reglementiert ist und somit oft Grundsatzfragen für sich, mit Kunden oder Zulieferern geklärt werden müssen.

Insbesondere in der Marinetchnik ist der Trend hin zu einer zunehmenden Komplexität mechatronischer Systeme und Subsysteme erkennbar. Diese Komplexität resultiert zum einen aus einem zunehmend größeren bzw. komplizierteren Funktionsumfang und zum anderen aus der Dynamik des Systems. Insbesondere durch den steigenden Einsatz von Software, die die oben genannten Merkmale verstärkt, erfolgen markante Eingriffe in die funktionalen und sicherheitsrelevanten Eigenschaften der Systeme. Dem zufolge stellt sich im Verlauf ein gesteigertes Bedürfnis nach Sicherheitsanforderungen auf Kundenseite ein.

## **5. Einführung Safety-Management**

Sicherheit beginnt initial mit der Führung und Engagement des Managements. Ohne diese Eigenschaften sind die Bemühungen anderer in einer Organisation quasi zum Scheitern verurteilt. In Folge dessen schafft Führung eine Kultur (vgl. Kapitel 6), die das Verhalten antreibt [3].

Die Gewährleistung der Sicherheit, (engl. „Safety“) spielt in der Produktentwicklung eine herausragende Rolle aufgrund einer vielfältigen Anforderungslage. Diese umfasst neben vertraglichen Aspekten, die von der Kundenseite in jedem Projekt individuell definiert werden, auch gesetzliche Aspekte, die umgesetzt werden müssen. Die kaum übersehbare Vielfalt nationaler und internationaler Gesetze und deren z.T. vorhandene Widersprüchlichkeiten erhöhen den zu leistenden Aufwand beim Management der Anforderungen, die im Zuge der Globalisierung schwer beherrschbar sind [4].

Die Gewährleistung der Sicherheit wird in der deutschen Sprache nicht in „Safety“ und „Security“ Begriffe unterteilt/definiert. Wir betrachten in der Produktentwicklung nur den Safety-Bereich, dies bezeichnen wir als die sog. „innere Sicherheit“ und grenzen den Security-Bereich von unseren Analysen ab, da dieser zur Analyse von externen Fehlern, Sabotage, Innentätern, Angriffen etc. hinzugezogen wird und somit nicht unseren Bereich der Produktsicherheit im funktionellem Sinne des Produktes bildet.

## **6. Safety Culture**

Das Fundament eines erfolgreichen Safety Managements und -Engineerings und somit eine nachhaltige Umsetzung von Produktsicherheit ist eine im Unternehmen etablierte Sicherheitskultur (Safety Culture). Eine solche Safety Culture beinhaltet zum einen das persönliche Engagement sowie die Kompetenz jedes Einzelnen, der bei der Umsetzung der Entwicklung beteiligt ist und zum anderen ein Bewusstsein in der gesamten Organisation, das

ein Hinterfragen von Lösungen zulässt (und damit das Aufdecken von potentiellen Risiken im Design), somit Selbstgefälligkeit verhindert und die Übernahme von Verantwortung in Produktsicherheitsfragen fördert. Die International Nuclear Safety Group [5] formulierte es so: „Sicherheitskultur ist jene Zusammenstellung von Merkmalen und Haltungen in Organisationen und Einzelpersonen, die festlegt, dass Fragen der Sicherheit [...] als übergeordnete Priorität die Aufmerksamkeit erhalten, die ihre Bedeutung rechtfertigt.“ Die nachfolgende Abbildung zeigt die die Safety-Culture beeinflussenden Aspekte.



Bild 1: Einflussfaktoren der Safety Culture

Eine Organisation, die sicherheitsrelevante Produkte herstellt, muss die für die Erreichung der Produktsicherheit erforderlichen Ressourcen bereitstellen. Zu den Ressourcen gehören Humanressourcen, Werkzeuge aber auch angemessene Entwicklungsumgebungen sowie Richtlinien und Arbeitsanweisungen. Darüber hinaus muss die Organisation sicherstellen, dass die Personen, die für die Durchführung oder Unterstützung der Entwicklung in sicherheitsrelevanter Technik verantwortlich sind, ausreichende Kenntnisse und auch Befugnisse erhalten, um ihre Verantwortlichkeiten zu erfüllen. Kommunikationskanäle bzw. Entscheidungswege müssen vorhanden und allen Beteiligten zugänglich sein.

Der Prozess muss sicherstellen, dass die Verantwortlichkeiten für Entscheidungen im Zusammenhang mit der funktionalen Sicherheit nachvollziehbar sind. Er sollte angemessene Überprüfungen und Abwägungen bieten, wie etwa das angemessene Maß an Unabhängigkeit in den integralen Prozessen (Sicherheit, Qualität, Verifikation, Validierung und Konfigurationsmanagement). Sicherheits- und Qualitätsprobleme sollen bereits in den frühen

Phasen des Produktlebenszyklus entdeckt und gelöst werden. Hierzu müssen neben dem Design selber auch die jeweiligen Entscheidungen, die zu eben diesem Design geführt haben, in einer aussagekräftigen Architektur dokumentiert werden.

Die Mitarbeiter müssen zum einen mit den einschlägigen relevanten Normen vertraut sein und auch den etablierten Prozess leben. Sie haben die Kompetenz, die der zugewiesenen Aktivität entspricht. Darüber hinaus sollte aber auch proaktiv der Austausch mit anderen Gewerken als der eigenen erfolgen. Wichtig ist auch das Lernen aus den Erfahrungen, die während der Umsetzung vorhergehender Entwicklungen, einschließlich der Felderfahrung, gewonnen wurden und die daraus abgeleiteten Verbesserungen zur Anwendung auf nachfolgende Produkte.

Grundsätzlich kennzeichnet die Abwesenheit einer Safety Culture die Negierung oben genannter Aspekte. Das gravierendste Merkmal einer nicht gelebten Safety Culture sind jedoch Aussagen wie „das ist zu aufwendig,“ „das ist zu teuer“ oder „das würde zu lange dauern.“ Dies bringt einen wichtigen Punkt bezüglich der Umsetzung von Funktionaler Sicherheit im Speziellen und Produktsicherheit im Allgemeinen hervor: Safety kostet nur dann weniger, wenn sie frühzeitig in die Produktentwicklung einbezogen wird (vgl. Kapitel 11).

Es ist nicht leicht, eine Safety Culture zu etablieren, und auch die Aufrechterhaltung (wobei von einer solchen streng genommen auch nur im Falle der kontinuierlichen Verbesserung gesprochen werden kann) geschieht nicht von alleine. Dort, wo es dennoch gelungen ist, erhält man dafür eine nachhaltige Produktsicherheit, die nicht nur durch das Ausfüllen von Checklisten erarbeitet wird, sondern die durch die selbstverständlichen Beiträge jedes Einzelnen erreicht werden kann.

## **7. Der Normeneinsatz im System-Safety-Prozess**

### **Zweck des Normeneinsatzes**

Der Hersteller ist frei in der Nutzung von Normen. Dies bedeutet, er kann auf die Verwendung von Normen verzichten und für sich selber definieren wie er eine Umsetzung durchführen will. Mit einem solchen Vorgehen kommt er im Fall eines Produktsicherheitsvorfalls in die Situation zu beweisen, dass seine Umsetzung dem Stand der Technik entspricht, der durch die aktuelle Normenlage dargestellt wird. Die Verwendung von Normen mindert dieses Risiko und kann zusätzlich dazu genutzt werden, die Qualitätskriterien und Umsetzung mit dem Kunden in der Angebotsphase abzustimmen.

## Einführung MIL-STD 882

Seit der ersten Veröffentlichung im Juli 1969 gilt der MIL-STD 882 des US-Verteidigungsministeriums (Department of Defence - DoD) als primäres Referenzdokument für die Systemsicherheit (System-Safety). Der Standard, der mittlerweile in der Edition „E“ von 2012 vorliegt, identifiziert die systemtechnischen Ansätze um Gefährdungen zu eliminieren wo dies möglich ist und ermittelt die Grundzüge zur Risikominimierung wo Gefährdungen nicht beseitigt werden können. „Safety“ wird vom MIL-STD-882 als die Freiheit von Umständen, die zu Tod, Verletzung, arbeitsbedingten Krankheiten sowie zu Schaden oder Verlust von Equipment oder Eigentum führen können, beschrieben. [6]

Der Systemsicherheitsprozess besteht nach MIL-STD 882 aus acht Elementen. Die folgende Abbildung stellt die typische logische Abfolge des Prozesses dar. Grundsätzlich kann jedoch eine Iteration zwischen den Schritten erforderlich sein. [6]

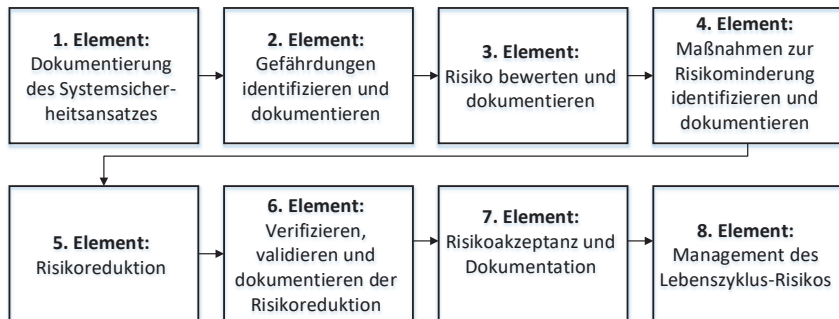


Bild 2: Acht Elemente des Systemsicherheitsprozesses, nach [6]

## Der MIL-STD 882 als „Werkzeugkasten“ innerhalb der Normenwelt

Militärische Normen decken einen Bedarf, die zivile Normen nicht bedienen können (z.B. sichere Sprengköpfe) oder nicht bedienen konnten (Wurzeln des MIL-STD-882 liegen in den 1950er Jahren). Als Unternehmen der Defense Branche nutzt die ATLAS ELEKTRONIK GmbH den MIL-STD-882 um sämtliche Safety Aktivitäten zu initiieren und zu verwalten.

Der MIL-STD-882 sticht aus der Normenwelt heraus, da er alle Aspekte der Produktsicherheit bedient. Er teilt diese in vier Bereiche auf [6]:

- 100er Tasks: Management/ Planung der Safety Aktivitäten
- 200er Tasks: Analyseverfahren (z.B. Preliminary-, System Requirements-, Functional-, Health-, System-of-Systems und Environmental Hazard Analysis)
- 300er Tasks: Werkzeuge zur Evaluierung der Safety Planungen und Aktivitäten

- 400er Tasks: Verifikationsmethoden

Die folgende Abbildung stellt graphisch die Einbettung des MIL-STD 882 im Zusammenhang mit weiteren einschlägigen Fachnormen und Richtlinien dar. Sie zeigt auch die vertikale Zuständigkeit der betrieblichen Akteure von oben (Safety Management) nach unten (Sachverantwortliche im Engineering). In der Praxis verläuft diese Abgrenzung jedoch nicht in diskreten Schritten, sondern kontinuierlich.

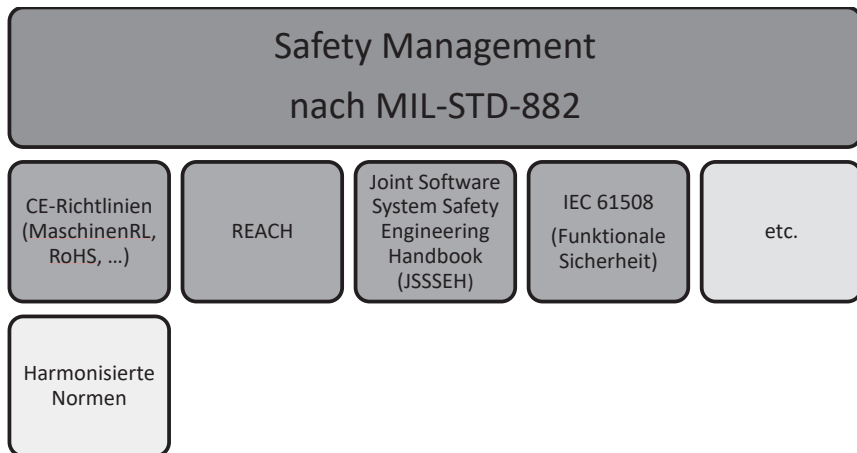


Bild 3: Der MIL-STD-882 als übergeordnete Norm/Prozess über alle Safety Aspekte (fließender Übergang Management (dunkler) zum Engineering (heller))

Durch diesen Fassettenreichtum kann der MIL-STD-882 sehr gut auf ein spezifisches Vorhaben skaliert werden. Es ist nicht das Ziel, alle Tasks des Standards auszuführen, sondern diese fachlich sinnvoll zu wählen. Diese Vielseitig- und Anpassbarkeit lässt den MIL-STD-882 in der Welt der Normen hervorragen.

### **Vorstellung ausgewählter ziviler Normen: IEC 61508 / EN 13849 / ISO26262**

In Ergänzung zum MIL-STD-882E werden zur Erweiterung des Safety Management Industrienormen herangezogen. Dies sind konkret mit der DIN EN 61508 die Grundnorm für sicherheitsrelevante Elektronik-Systeme/SW-Systeme, die B-Norm für Sicherheit von Maschinen EN ISO 13849 sowie die Automotive Norm ISO 26262, die Methoden und Verfahren einführt, die auch im Safety Management außerhalb der Automobilindustrie ihre Verwendung finden, wie z. B. den Safety Case (Sicherheitsnachweis) oder auch das Hardware-Software-Interface (HSI).

Die IEC 61508 befasst sich mit der Funktionalen Sicherheit sicherheitsbezogener elektrischer/elektronischer/programmierbarer elektronischer Systeme. Mit „sicherheitsbezogen“ (vgl. [7]) sind hierbei Systeme gemeint, die eine Funktion (oder Funktionen) ausführen, die das verbleibende Risiko des Gesamtsystems, in dem diese sog. Sicherheitsfunktion ausgeführt wird, auf ein akzeptables Restrisiko reduzieren. Die Anforderungen an die Sicherheitsfunktion folgen aus einer Gefährdungsanalyse. Darüber hinaus gibt es Anforderungen an die Sicherheitsintegrität, die aus der Risikobeurteilung resultieren. „SIL 1“ kennzeichnet hierbei die geringste Sicherheitsintegrität, „SIL 4“ die höchste. Ein sicherheitsbezogenes System kann vom vorhandenen Steuerungssystem getrennt sein oder dieses kann selbst Sicherheitsfunktionen ausführen.

Die EN ISO 13849-1 [8] ist als harmonisierte Norm im Sinne der Maschinenrichtlinie für den Bereich „Sicherheit von Maschinen“ anzuwenden. Hierbei werden zunächst die Anforderungen an die Sicherheitsfunktionen definiert und dann im zweiten Schritt die zutreffenden Performance Level (PL) festgelegt. Performance Level klassifizieren den jeweiligen Beitrag zur Risikominimierung, wobei "a" die niedrigste Stufe darstellt und "e" die höchste.

Eine Ableitung der IEC 61508 für Kraftfahrzeuge ist die ISO 26262. Seit Dezember 2018 ist sie in der „Second Edition,“ der ISO 26262:2018 [9], verfügbar. Die Sicherheitsintegritätslevel reichen hier von „ASIL A“ (geringster) zu „ASIL D“ (höchster). ASIL D entspricht einem SIL 3. Als Ergänzung zur ISO 26262 existiert der ISO/PAS 21448 SOTIF (Safety of the intended functionality) [10], in dem Ansätze zur Beurteilung autonomer Systeme beschrieben sind. Die Anwendung der beschriebenen Methoden erhöht die Durchdringung des Systems und verbessert somit die Grundlage zur Beurteilung des dazu gehörigen Risikos. Darüber hinaus sei erwähnt, dass die Verwendung branchenfremder Normen dazu dient, den Stand der Technik abzubilden.

## JSSSEH

In neu entwickelten Systemen spielt die Software eine zunehmende Rolle. In der Regel ist sie der Hauptfunktionsträger, so dass Fehler in der Software zumindest mittelbar zu Fehlern im Gesamtsystem führen. Es bleibt nicht aus, dass Software in safety-relevanten Systemen selbst sicherheitsrelevant ist. Per Definition gibt es in Software keine zufälligen Fehler, vielmehr sind diese Fehler systematischer Natur – Timings und Ressourcen sind nicht sauber verwaltet, der Programmablauf ist nicht deterministisch und durch die Verwendung von Zeigern oder nicht überwachtem Zugriff auf Arrays kommt es zu Speicherzugriffsfehlern und damit zu unerwartetem Systemverhalten (um nur einige wenige Beispiele zu nennen). Das Problem der Software-Sicherheit muss also durch rigide Qualitätssicherungsmaßnahmen erfolgen. Für die

Umsetzung solcher Maßnahmen und damit von Software Safety Engineering verweist der MIL-STD-882 auf das Joint Software System Safety Engineering Handbook (JSSSEH) [11]. Software System Safety Engineering (SSSE), (vgl. Abbildung 4), befasst sich mit zwei Aspekten (vgl. [11]): erstens Software mit dem entsprechenden Level-of-Rigor (LOR) zu entwerfen, zu codieren sowie zu testen, um das Vertrauen in eine sichere Software zu schaffen, und zweitens die notwendigen Sicherheitsanforderungen für das Design, den Code, den Test, die Verifikation und die Validierung von Software zu definieren, die speziell auf die Software-"Ursachen" der definierten Gefahren und Pannen des Systems abzielen und diese mindern.




Bild 4: Einflussgrößen auf das SSSE, [11]

Die genannten Aspekte und die zugehörigen Maßnahmen sind im JSSSEH beschrieben. Die Herausforderung besteht darin, genau zu spezifizieren, wie sie die Ziele des MIL-STD-882E unter Zuhilfenahme des JSSSEH in konkrete Requirements für Software und deren Entwicklung umsetzen werden. Das Ergebnis ist ein Prozess, der die Definitionen und Abläufe beschreibt, die für die Durchführung eines Software-Safety-Programms erforderlich sind. Für die konkrete Umsetzung sei auf den JSSSEH Implementation Guide [12] verwiesen.

## 8. ProdSG und CE-Kennzeichnung

Das Produktsicherheitsgesetz (ProdSG) hat den Zweck des Schutzes der Gesundheit von Verbrauchern und Arbeitnehmern indem es bestimmt, unter welchen Bedingungen Produkte auf dem Markt bereitgestellt werden dürfen. Die CE-Kennzeichnung ist in Deutschland im ProdSG und seinen Produktsicherheitsverordnungen (ProdSV) und weiteren nationalen



Gesetzen geregelt. Diese Gesetze setzen damit die ca. 30 Richtlinien um, die verschiedene Schutzziele verfolgen. Insbesondere im Bereich der Marineelektronik sind die folgenden Richtlinien häufig in der Anwendung:

- Maschinenrichtlinie (9. ProdSV)
- Niederspannungsrichtlinie (1. ProdSV)
  - EMV-Richtlinie (EMVG)
  - Funkanlagenrichtlinie (FuAG)
- Druckgeräte richtlinie (14. ProdSV)
- RoHS (ElektroG)

Das ProdSG ist anzuwenden, wenn im Rahmen einer Geschäftstätigkeit Produkte auf den Markt bereitgestellt werden, ausgestellt werden oder erstmals verwendet werden. Dies umfasst jede entgeltliche oder unentgeltliche Abgabe eines Produktes zum Verbrauch, Vertrieb bzw. zur Verwendung auf dem Markt der EU im Rahmen einer Geschäftstätigkeit. Im Bereich des öffentlichen Rechts hat das CE-Kennzeichen den Charakter einer gesetzlich zwingenden Regelung, im Zivilrecht erklärt der Hersteller gegenüber einer Behörde die Beachtung der gesetzlichen Vorschriften.

In der Marineteknik zeigt sich, dass bereits in den Vertragswerken umfassende Vereinbarungen zunehmen. Das ist insofern bemerkenswert, als dass die Produkte der Marineteknik aufgrund der eingesetzten Effektoren z.T. das vertraglich vereinbarte Entwicklungsziel ausweisen, „gefährlich“ zu sein, also eine gewisse Kritikalität bis zur Auslieferung an den Kunden niemals loswerden. Dieser Umstand unterscheidet sich klar von der Situation in rein zivilen Produkten, insbesondere solche für den privaten Endkunden.

Parallel sind Unternehmen mit zunehmend anspruchsvolleren Rahmenbedingungen durch die Gesetzgebungen konfrontiert, bspw. durch das Gefahrstoffrecht (RoHS). Zwar existieren für spezielle Anwendungen der Sicherheitstechnik Ausnahmen in diesem Bereich, um z.B. ein hohes Maß an Zuverlässigkeit der Systeme zu gewährleisten, jedoch verlangen Kunden häufig hier eine strikte Substitution gefahrstoffbewerter Komponenten.

## 9. Der bewährte Prozess

Der System Safety Prozess sollte keine getrennte Prozessbeschreibung sein. Safety ist eine inhärente Eigenschaft des Produktes und so muss der Prozess das Thema Safety auch inhärent umsetzen. Die Produktsicherheit geht zentral von der Organisationsführung aus. Deswegen ist im Produktsicherheitsgesetz klar geregelt, dass der Hersteller einen Bevollmächtigten schriftlich ernennen muss, damit diese Thematik delegiert werden kann,

aber es verbleibt grundsätzlich beim Hersteller. Ein Bevollmächtigter kann auch sinnvoll sein, da das Themenspektrum wie oben gezeigt sehr umfangreich ist.

Der oder die Prozesse des Unternehmens sollten immer einen Bezug zur Produktsicherheit ausweisen. Von der Akquirierung von Projekten bis zur Auslieferung und der Marktbeobachtung danach gibt es immer etwas festzulegen, zu analysieren oder in der Umsetzung zu beachten. Natürlich kann der Safety Management Prozess gesondert ausgeprägt sein, ersetzt aber nicht die Aspekte z.B. in der Konstruktion.

## **10. Analysetechniken**

### **FTA**

Die Fehlerbaumanalyse, engl. Fault Tree Analysis (FTA), wird eingesetzt, um alle systematischen Ausfallkomponenten in technischen Anlagen und Systemen, die miteinander verbunden sind, aufzudecken. Ein Fehlerbaum wird durch die deduktive Analysemethode nach dem Top-Down Prinzip aufgebaut, wobei sich durch das Betrachten des Top Ereignisses die Baumstruktur nach unten hin konstruiert. Beim Einsatz dieser Methodik ist es ausschlaggebend, die Systemgrenzen vorab mit einem hohen Detaillierungsgrad zu definieren. Diese Eingrenzung setzt in der Analysephase das Hauptaugenmerk auf das zu betrachtende Schutzgut, welches in diesem Fall als Top Ereignis bezeichnet wird. Dieses dient der strukturierten Vorgehensweise bei der Ermittlung der Fehlerursache in dem betrachteten System. Durch diese Maßnahmen, werden die grundlegenden Ursachen analysiert. Das detaillierte Auffinden der Fehlerursache, bringt einher, dass die Wahrscheinlichkeit des Auftretens der Fehler bis zur kleinsten Komponente reduziert werden kann. Die Anwendung dieser Methode ist zwar zeitaufwendig, allerdings ist die Fehlerbaumanalyse in der Sicherheitstechnik im Safety- und im Securitybereich unabhängig anwendbar und zielführend bei der Fehlerdetektion. Des Weiteren können durch die frühzeitige Ermittlung der möglichen Fehlerquellen die Entwicklungs- und Produktionskosten nachhaltig kalkuliert und minimiert werden.




Bild 5: Beispiel für die graphische Strukturierung von Kausalitäten im Fehlerbaum

## FMEA

Die Failure Mode and Effects Analysis (FMEA) wurde parallel zur Fault Tree Analysis (FTA) entwickelt. Die FMEA ist im Gegensatz zur FTA eine induktive Bottom-Up Methode. Diese beiden Analysemethoden entwickeln durch eine Kombination, in Hinsicht der Risikoidentifikation, einen großen Wirkungsmechanismus. Die FMEA versucht herauszufinden, wie einzelne Ausfallarten und die Auswirkungen dieser Ausfallarten sich auf das System verhalten. Die FMEA wird also als fehlerverhütende präventive Methode verwendet, um Fehler so früh wie möglich im Prozess / System zu entdecken. [13]

## 11. Kommerzielle Aspekte zur Systemsicherheit

Der Kostenaspekt bei der Systemsicherheit ist zweischneidig: Einerseits sind die Kosten für die Durchführung betrieblichen Prozesse, die der Systemsicherheit zugeordnet sind zu nennen, andererseits entstehen Kosten, wenn die Systemsicherheit nicht implementiert wird. Ein ineffizienter Systemsicherheitsprozess verursacht einen Dominoeffekt: Ein unsicheres System wird weiterhin solange Fehlfunktionen aufweisen, bis ernsthafte Maßnahmen ergriffen werden um das System korrekt und vollständig zu justieren. Hier existiert eine inverse Korrelation: Mit zunehmender Sicherheit nehmen die Fehlfunktionen bzw. Unfälle ab.

Sinnbildlich besteht hier ein Gleichgewicht: Es entstehen Aufwendungen, um die Systemsicherheit zu erhöhen, aber wenn diese nicht erhöht wird, kostet es diverse, auch monetäre Mittel, um für Unfallschäden zu entschädigen und dann Nachbesserungen vorzunehmen, die von vornherein hätten vorgenommen werden sollen. Safety sollte daher als Investmentkostenpunkt gesehen werden. Ein durch proaktives Safety-Management gesteuertes Engineering ist eine Investition in die Zukunft. Herausfordernd kann, wie im Kapitel 6 beschrieben, die innerbetriebliche Akzeptanz zur Notwendigkeit der Safety-Aktivitäten trotzdem sein. Safety-Management und Safety-Engineering sind inhärente Bestandteile des Systems Engineerings und damit Teil der Wertschöpfungskette. Zusammengefasst lässt sich sagen, dass Sicherheitsmaßnahmen zwar nicht kostenlos sind, jedoch typischerweise preiswerter als alle Alternativen. [14]

## 12. Zusammenfassung und Ausblick

Im Beitrag konnte gezeigt werden, dass das die ingenieurwissenschaftliche Disziplin des Safety-Managements einen ganzheitlichen Ansatz darstellt, um in der Design- und Entwicklungsphase eines Systems Gefährdungen zu identifizieren und diese zu lindern oder vollständig zu eliminieren. Vereinfacht ausgedrückt geht es bei der Systemsicherheit letztlich darum, Leben zu retten bzw. zu schützen oder schwere Umweltkatastrophen zu verhindern. Dies zeigt die enorme Reichweite der Safety-Aspekte, die weit über qualitative Ansprüche im Unternehmen hinausgehen. Hierbei ist zu bemerken, dass die Zuverlässigkeitstechnik eine wesentliche Säule im Systemdesign ist, welche einen großen Einfluss auf das Restrisiko im operationellen Betrieb von Systemen aufweist. Der Rolle des Safety-Managements kommt die besondere Bedeutung zu, einen Schaden von allen beteiligten Safety-Bereichen abzuwenden. Ein wirksames Mittel hierbei ist eine lückenlose Dokumentation der Prozesse mit sicherheitsrelevantem Bezug und eine Entwicklung auf dem Stand der Technik mit der Anwendung anerkannter Standards und Normen.

## 13. Literaturangaben

- [1] Winzer, P.: Generic Systems Engineering. 2. Auflage. Springer Vieweg Berlin Heidelberg 2016
- [2] Verma, A. et al.: Reliability and Safety Engineering. 2. Auflage. Springer London 2016
- [3] Leveson, N.: Engineering a Safer World. Massachusetts Institute of Technology, The MIT Press Cambridge, Massachusetts, London, England 2011
- [4] Winzer et al. (Hrsg): Sicherheitsforschung; Chancen und Risiken (acatech diskutiert). Springer Berlin, Heidelberg 2010

- [5] International Nuclear Safety Advisory Group: Safety Culture, INSAG-4, IAEA, Vienna (1991)
- [6] U.S. Department of Defense: MIL-STD-882E, DoD Standard Practice for System Safety. Washington, D.C. 2012
- [7] Deutsches Institut für Normung: DIN EN 61508 / VDE 0803: Funktionale Sicherheit sicherheitsbezogener elektrischer / elektronischer / programmierbarer elektronischer Systeme, 2010
- [8] Deutsches Institut für Normung: EN ISO 13849 Sicherheit von Maschinen – Sicherheitsbezogene Teile von Steuerungen – Teil 1: Allgemeine Gestaltungsleitsätze, 2015
- [9] International Organization for Standardization: ISO 26262-2:2018-12 Straßenfahrzeuge - Funktionale Sicherheit, 2nd Edition, 2018
- [10] International Organization for Standardization: ISO/PAS 21448:2019-01 Road vehicles - Safety of the intended functionality, 2019
- [11] U.S. Department of Defense: Joint Software Systems Safety Engineering Handbook, Version 1.0, August 27, 2010
- [12] JS-SSA Sub-Working Group: Software System Safety Implementation Process and Tasks Supporting MIL-STD-882E, Rev. B., 2018
- [13] Rautenstrauch T., Hunziker S.: Risikoidentifikation mit Hilfe der Fehlerbaumanalyse (FTA) sowie der Fehlermöglichkeit- und Einflussanalyse (FMEA). WEKA Business Media AG Zürich 2008
- [14] Ericson II, C. A.: System Safety Primer. CreateSpace Independent Publishing Platform, First Thus Edition, 2011



# Zuverlässigkeitsmanagement und Haftungsfragen – ein Betrag zur Existenzsicherung im Unternehmen

## Zuverlässigkeitsmanagement

Prof. Dr.-Ing. **Andreas Braasch**,

Institut für Qualitäts- und Zuverlässigkeitsmanagement GmbH,

Wuppertal und Hochschule Ruhr West, Mülheim a.d. Ruhr;

**Harald Wüsteney**,

Allianz Risk Consulting Liability, München;

Dr.-Ing. **Fabian Plinke**,

Institut für Qualitäts- und Zuverlässigkeitsmanagement GmbH, Hamburg

### KURZFASSUNG

Kürzere Entwicklungszeiten, hohe Systemkomplexität, verlängerte Gewährleistungsfristen – das sind die Schlagworte, aus denen sich die Herausforderungen für Hersteller und Zulieferer komplexer Systeme ergeben und denen es sich in heutiger Zeit zu stellen gilt. Immer wieder zeigte sich im Rahmen öffentlichkeitswirksamer Rückrufe eindrucksvoll, dass nicht alle Systeme vor dem Inverkehrbringen die notwendige Reife hinsichtlich Sicherheit und Zuverlässigkeit erreichen. Verschärft wird diese Thematik durch den Einsatz von Gleichteil- und Plattformstrategien, die auf den ersten Blick durch erhebliche Skaleneffekte attraktiv erscheinen, jedoch hinsichtlich Risikopotential von großen Serienschäden einer ganzheitlichen Risikobetrachtung bedürfen. Aber auch in der vertraglichen Haftung, sprich der Haftung für Sachmängel, schlummert ein enormes Risikopotential, welches besonders für mittelständische Unternehmen zur existenziellen Bedrohung werden kann.

Gut beraten scheint in diesem Fall jeder, der Risiken zum einen vertraglich entlang der Lieferkette diversifizieren kann, und einen entsprechend qualifizierten Versicherungsschutz besitzt. Dabei wird oftmals vergessen, dass eine gewisse Sorgfaltspflicht im Rahmen der Entwicklung, Produktion und Marktphase nicht nur die Fehlerhäufigkeit reduzieren soll. Neben diesem primären Ziel, Ausfälle überhaupt nicht entstehen zu lassen, sorgt die konsequente Umsetzung von Qualitäts-, Sicherheits- und Zuverlässigkeitsstandards auch für den Nachweis des Stand der Technik. Dieser Stand der Technik ist immer wieder Streitgegenstand bei der deckungsrechtlichen Auseinandersetzung zwischen Versicherungskonzernen und Versicherungsnehmern.

Dieser Beitrag soll die aktuellen und zukünftigen Herausforderungen für Inverkehrbringer technischer, komplexer Systeme im Kontext möglicher Haftungsfragen und Unternehmensrisiken aufzeigen. Dabei wird aufgezeigt, welche haftungsrechtliche Bedeutung die Einhaltung von QM- und Zuverlässigkeitsstandards haben. Besonders wird auf die deckungsrechtlich relevanten Themen „Stand der Technik“, „Erprobungsklausel“ und „Organisationsverschulden“ eingegangen.

#### INNOVATIONSGRAD

Dieser Beitrag soll nicht den wissenschaftlichen Anspruch eines statistischen Fachpapers erfüllen, sondern den Teilnehmern\*innen die Bedeutung und Tragweite Ihrer Arbeitswelt, gerade auch im Kontext von Haftungsrisiken und Versicherbarkeit, darlegen. Damit erhoffen wir schlagkräftige Argumente vorzubringen, warum sich Unternehmen ganzheitlich mit den Themen Sicherheit und Zuverlässigkeit beschäftigen müssen. Der Beitrag soll daher als Mahnung, aber auch Motivation für Zuverlässigkeitsexperten dienen.

#### VORPUBLIKATIONEN

Braasch, A.; Haller, S.:	Zuverlässigkeit im Entwicklungsprozess. Tagungsband Bergisches Qualitätsforum und zugleich GQW Jahrestagung, Wuppertal, 25.02.2015.
Metzele, M.; Braasch, A.:	Zuverlässigkeitsmanagement im Entwicklungsprozess - Mit Service- und Gewährleistungsdaten zum abgesicherten Serienprodukt Deutscher QM-Kongress, Göttingen, 29.-30.11.2016
Braasch, A.:	Stärkung der Verhandlungsposition im Regressfall: Moderne Früherkennungsmethoden in der Felddatenauswertung 1.NRW-Automobilkonferenz: Haftungsmanagement für die Automobilzulieferer-Industrie, Gütersloh, 23.05.2017
Braasch, A.:	Die automobile Welt im Wandel – Auswirkungen auf die Lieferkette Automobilzuliefererindustrie 2018, Hornbach, 27.09.2018



# Zuverlässigkeitsnachweis entlang des Produktentwicklungsprozesses – Herausforderungen in der praktischen Umsetzung

Prof. Dr.-Ing. **Tobias Leopold**, Hochschule Esslingen

## Kurzfassung

Der Nachweis der Produktzuverlässigkeit ist eine herausfordernde Tätigkeit während der Entwicklung eines technischen Produktes. Von elementarer Bedeutung ist zunächst die Definition eines Zuverlässigkeitszieles. In der Praxis treten hier gelegentlich Missverständnisse und Schwierigkeiten auf. Einige dieser Aspekte werden im Rahmen dieses Beitrags veranschaulicht. Auf weitere praktische Herausforderungen v.a. in der Planung von Lebensdauertests wird im zweiten Teil des Beitrags eingegangen. Zu beiden Themenbereichen werden, soweit dies generell möglich ist, Lösungsansätze vorgestellt.

## 1. Bedeutung der Produktzuverlässigkeit

Die Haltbarkeit von Produkten während des Kundengebrauchs ist für qualitativ hochwertige Produkte eine zentrale Produkteigenschaft, die häufig über den Markterfolg von Produkten und damit auch von Unternehmen entscheidend ist [6]. Somit nimmt die Produktzuverlässigkeit während der Produktentwicklung eine Schlüsselrolle ein. Neben dem Einsatz von qualitativen und quantitativen Zuverlässigkeitsmethoden [1] ist insbesondere die Nachweisführung einer ausreichenden Produktzuverlässigkeit eine große Herausforderung.

Innerhalb der Zuverlässigkeitsmethoden haben quantitative Ansätze die positive Eigenschaft, dass diese prinzipiell immer anwendbar sind. So wird beispielsweise in der Automobilindustrie flächendeckend die FMEA eingesetzt. Nach der Festlegung des Betrachtungsumfangs stehen die Anforderungen sowie die Systemstruktur im Fokus. Weitere Analyseschritte führen schließlich zu detaillierten Risikoanalysen mit Ableitung von Handlungsbedarf in Form von Vermeidungs- und Entdeckungsmaßnahmen. Entscheidend sind die verfügbaren Informationen und das Knowhow, das innerhalb des FMEA-Teams vorhanden oder generiert wird. Davon sind die Ergebnisse der FMEA direkt abhängig. Diese qualitative Zuverlässigkeitsmethode kann sowohl im Kontext qualitativer als auch quantitativer Anforderungen durchgeführt werden. Oftmals bleibt jedoch offen, welches absolute Qualitäts- und Zuverlässigkeitsniveau im Rahmen einer frühen Phase einer Produktentwicklung zu erreichen ist bzw. welches Niveau in einer

späteren Projektphase erreicht wurde. Für diese Fragestellung ist die Anwendung quantitativer Zuverlässigkeitsmethoden unumgänglich.

## 2. Definition von Zuverlässigkeitszielen

In der Definitionsphase eines Produktentwicklungsprojektes sind die Anforderungen an die Produktzuverlässigkeit festzulegen. Die Anforderungen können sich allgemein an der Definition der Produktzuverlässigkeit orientieren [1]: „Zuverlässigkeit ist die Wahrscheinlichkeit dafür, dass ein Produkt während einer definierten Zeitdauer unter gegebenen Funktions- und Umgebungsbedingungen nicht ausfällt.“

Die Funktions- und Umgebungsbedingungen stellen die Einsatzbedingungen dar, also die Nutzergewohnheiten im Umgang mit dem Produkt in einer gewissen Einsatzumgebung, was schließlich eine Produktbelastung verursacht. Diese Produktbelastung ist meist sehr anwenderspezifisch und somit wiederum spezifisches Produkt-Knowhow bzw. Markt-Knowhow. In der Praxis müssen somit die Kundenstrukturen und deren Anwendungsgewohnheiten ermittelt werden, um somit Aussagen über Produktbelastungen tätigen zu können.

Von zentraler Bedeutung für die Definition eines Zuverlässigkeitsziels ist die Festlegung der Ausfallwahrscheinlichkeit zu einer definierten Zeitdauer bzw. einem geeigneten Zeitpunkt. Hier treten in der Praxis oftmals große Herausforderungen auf, wenn keine eindeutigen und stimmigen Kundenvorgaben vorhanden sind. Mit der Materie der Zuverlässigkeitstechnik weniger versierte Anwender neigen gelegentlich dazu, einem nicht-sicherheitskritischen Produkt eine Ausfallwahrscheinlichkeit von 0% zuzugestehen. Die Auswirkungen auf die Produktgestaltung und den Lebensdauernachweis sind meist von hoher Tragweite, ebenso die Folgen für die Entwicklungsressourcen sowie Produkt- und Erprobungskosten, siehe Bild 2.

Ein weiterer pragmatischer Ansatz ist die relative Zielgestaltung, dass das Neuprodukt mindestens genauso gut sein muss wie sein Vorgängerprodukt. Diese Herangehensweise ist immer dann möglich, wenn die Zuverlässigkeit des Vorgängerprodukts ausreichend genau quantitativ beschrieben werden kann. Diese Produktzuverlässigkeit eines Vorgängerproduktes wird häufig aus Gewährleistungs- und Kulanzdatenbanken ermittelt. Insbesondere für langlebige Produkte wie beispielsweise Kraftfahrzeuge ist diese Datenbasis allerdings ungeeignet. Zum einen dienen derartige Gewährleistungs- und Kulanzdatenbanken meist einer organisatorischen und betriebswirtschaftlichen Abarbeitung von Kundenreklamationen. Technisch re-

relevante Ausfalldaten wie Belastungshistorie und Fehleranalyse sind für zuverlässigkeitstechnische Aussagen meist unzureichend [4]. Eine weitere Einschränkung dieser Datenquelle besteht in der oftmals praktizierten Analyse von sogenannten Testmärkten. Meist werden ausgewählte Länder bzgl. des Gewährleistungsaufkommens etwas genauer beobachtet. Dies schränkt allerdings wiederum die Kundenvielfalt und damit die Belastungsstreuungen ein.




Bild 1: Badewannenkurve [1]

Zum anderen treten bei Produkten mit einer Lebensdauererwartung, die deutlich größer ist als die gesetzliche Gewährleistungsdauer, Verschleiß- und Ermüdungsausfälle während der Gewährleistungszeit nur selten auf, siehe Badewannenkurve in Bild 1. Die typischen Ausfälle des dritten Bereichs der Badewannenkurve sind somit in den Gewährleistungsdaten nicht enthalten. Je nach Definition der Zeitdauer des Zuverlässigkeitsziels müssen diese Verschleiß- und Ermüdungsausfälle bei einer Zieldefinition der Produktzuverlässigkeit allerdings enthalten sein, da die Zieldefinition sonst eine zu große Ausfallwahrscheinlichkeit im Feld bei geringen Zeitdauern nicht ausschließen würde. Zusätzlich können die Erprobungsergebnisse, die v.a.

Verschleiß- und Ermüdungsausfälle enthalten werden, nicht mit den Zieldefinitionen auf Basis der Gewährleistungsdaten und damit von Früh- und Zufallsausfällen verglichen werden.

Eine weitere Einschränkung der Gewährleistungs- und Kulanzdaten tritt insbesondere bei kostengünstigen Produkten auf, wenn auch deren Folgekosten eines Ausfalls klein sind. In diesen Fällen werden oftmals keine oder nur vereinzelt Gewährleistungsanträge durch Kunden ausgefallener Produkte gestellt, da der Aufwand für die Reklamationsbeschreibung im Vergleich zu den erzielbaren Gewährleistungszahlungen als zu hoch empfunden wird. Die Ausfallwahrscheinlichkeiten auf Basis derartiger Gewährleistungsdaten wären folglich sehr klein. Diese zu kleinen Ausfalldaten nun als Zieldefinition für ein Neuprodukt zu verwenden, wäre fatal, da sehr ambitionierten Zuverlässigkeitsziele entstehen würden, mit entsprechender Kostenspirale bei einem kostengünstigen Vorgängerprodukt.

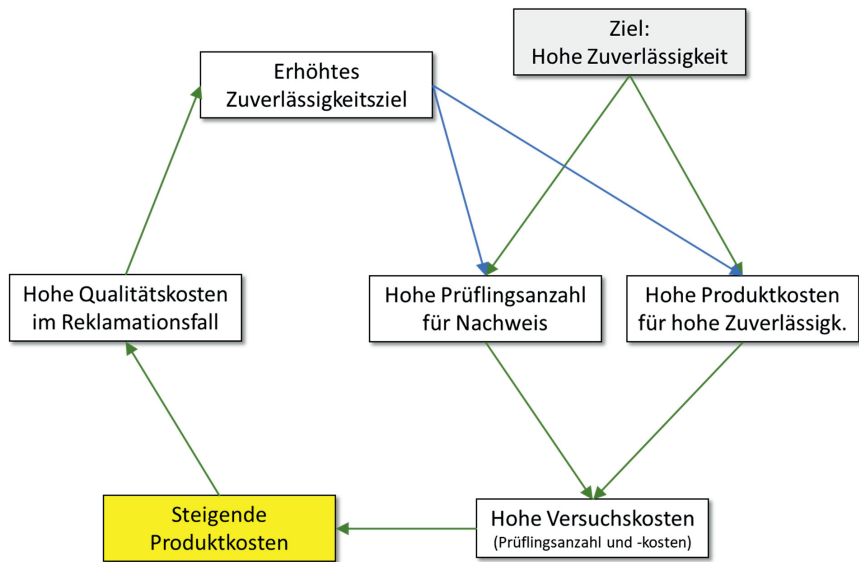


Bild 2: Kostenspirale für ambitioniertes Zuverlässigkeitsziel

Ein allgemeingültiger Lösungsansatz mit Erfolgsgarantie für die Definition eines Zuverlässigkeitsziels ist aus den beschriebenen Gründen nicht für alle praktischen Anwendungsfälle darstellbar. Ein Schlüsselement sind sicher Vorgängerprodukte oder Vergleichsprodukte, deren

Feldverhalten über Jahre und somit mittel- und langfristig genau beobachtet werden müssen. Diese Beobachtung schließt insbesondere die Belastungshistorie der Produkte mit ein und sollte keinesfalls auf die ausgefallenen Produkte beschränkt bleiben. Sollten keine Vorgänger- oder Vergleichsprodukte vorhanden sein, empfiehlt sich eine ausfallorientierte Lebensdauererprobung mit ausreichender Prüflingsanzahl, um die Produktzuverlässigkeit mit geringer Unsicherheit auf Prüfständen zu ermitteln. Eine gewisse Unsicherheit bei der Übertragung der Prüfstandsergebnisse auf das zu erwartende Feldverhalten ist wiederum mit Unsicherheiten verbunden, die minimiert werden müssen. Auch in hier ist ein mittel- und langfristiger Ansatz der Produktbeobachtung in Kundenhand unerlässlich. Bei absoluten Neuprodukten mit weitestgehend unbekannten Nutzergewohnheiten müssen Maßnahmen für eine schnelle Feedbackschleife von Feldinformationen bereits während der Produktentwicklung definiert und eingeleitet werden. Auch wenn nicht alle Unsicherheiten beseitigt werden können, so sollten diese zumindest abgeschätzt und somit bewusstgemacht werden.

## 2. Planung von Lebensdauertests

Sind ein Zuverlässigkeitsziel auf der Systemebene des Produkts und daraus abgeleitete Unterziele für Subsystemebene, Baugruppen und ggf. Einzelteile vorhanden und ist eine Aussagewahrscheinlichkeit für die Nachweisführung festgelegt, dann können die Möglichkeiten einer Lebensdauererprobung analysiert werden.

Oftmals bestehen herausfordernde Anforderungen an die Produktqualität, zumeist innerhalb eines kurzen Projektterminplans mit geringen budgetierten Produktentwicklungskosten. Da die Lebensdauertests zum Nachweis der erreichten Produktzuverlässigkeit oftmals lange dauern und hohe Kosten verursachen, ist eine geeignete Strategie der Nachweisführung enorm wichtig. Hier gilt es, eine gezielte Auswahl der Testphilosophie zu treffen, die grundsätzlich in Form einer ausfallfreien Lebensdauererprobung (success run bzw. reliability demonstration testing) oder einer ausfallorientierten Nachweisführung erfolgen kann [1], [5]. Beide Testphilosophien haben Vor- und Nachteile und sind insbesondere bei unterschiedlichen Voraussetzungen eines Produktentwicklungsprojekts differenziert zu bewerten.

Die Planung eines geeigneten Lebensdauertests erfordert neben einem vollständigen und plausiblen Zuverlässigkeitsziel die Berücksichtigung zahlreicher Randbedingungen, beispielsweise die Anzahl der verfügbaren Prüflinge und der verwendbaren Prüfstände. Zusätzlich sind Projektanforderungen wie Zeit- und Kostenvorgaben zu beachten. Sehr wichtig ist für eine zielgerichtete Testplanung eine Abschätzung des zu erwartenden Ausfallverhaltens des zu testenden Produkts. Insbesondere in frühen Projektphasen einer Produktentwicklung oder

wenn Lebensdauertests in Unternehmen nur sporadisch durchgeführt und ausgewertet werden sowie nur beschränkt verwendbare Felddaten zur Verfügung stehen, kann eine Testplanung wenig exakt sein und stellt nur eine Abschätzung des zu erwartenden Testprozederes dar.

Wenn bereits verlässliche Ausfalldaten vorhanden sind, können diese für eine Planung des Lebensdauertests verwendet werden, wie dies beispielsweise in [2] beschrieben ist. Mit diesem Ansatz kann eine meist iterative Testplanung durchgeführt werden und verschiedene Testszenarien bewertet werden.

Sollte die Datenbasis zum Zeitpunkt der Testplanung wenig verlässlich sein, so kann auf Basis stochastischer Simulationen versucht werden, über virtuelle Ausfalldaten eine Testplanung zu erzielen [3].

Für den Fall, dass das Ausfallverhalten absolut unbekannt sein sollte, ist eine Planung eines Lebensdauertests nur auf einem groben Genauigkeitsniveau möglich. Zunächst muss die Entscheidung für einen ausfallfreien oder einen ausfallorientierten Test gefällt werden. Ein pragmatischer Ansatz kann sein, dass zunächst einige Prüflinge bis zum Ausfall getestet werden, um eine erste Einschätzung des Ausfallverhaltens zu ermöglichen. Wie lange dieser Test voraussichtlich dauern wird, ist kaum abschätzbar. Eine Orientierung kann das Zuverlässigkeitsziel geben, das Produkt könnte aber im Vergleich zu diesem Ziel deutlich über- oder unterdimensioniert sein. Ohne vernünftige Planungsgrundlage, was auf diesen Fall zutrifft, muss die Unwägbarkeit einer undefinierten Testdauer akzeptiert werden und mittelfristig ein Zuverlässigkeitsmanagementsystem im Unternehmen aufgebaut werden.

Eine weitere denkbare Datenbasis für die Testplanung stellen Ausfalldaten von Vorgängerprodukten dar. Für die Verwendung dieses Vorwissens existieren zahlreiche Verfahren [1]. Wie gut das Ausfallverhalten eines Vorgängerproduktes mit einem aktuellen Produkt vergleichbar ist, kann mit Bestimmtheit immer erst nach einem Lebensdauertest beurteilt werden, was für die Planung eines Lebensdauertests zu spät ist. Eine Empfehlung kann deshalb lauten, das Vorwissen entsprechend kritisch zu beurteilen und später zu verifizieren.

Sollte die Entscheidung auf eine ausfallfreie Testdurchführung fallen, ist als Vorwissen meist ein Formparameter der Weibullverteilung notwendig [1]:

$$R_{\min}(t) = (1 - P_A)^{\frac{1}{L_V^{b \cdot n}}} \quad \text{mit } LV = \frac{\text{Prüfdauer}}{\text{Lebensdauerziel}}$$

Der Formparameter  $b$  wird häufig aus Ausfalldaten von Vorgängerprodukten abgeleitet. Wenn im Verlauf der Produktentwicklung ausschließlich Lebensdauertests auf Basis ausfallfreier Tests durchgeführt werden, kann der Formparameter des Neuprodukts nie ermittelt werden, da die Bestimmung eines Formparameters einer Weibullverteilung zwingend Ausfalldaten erfordert. Die ursprüngliche Annahme eines übertragbaren Formparameters von einem Vorgängerprodukt auf das Neuprodukt bleibt also ungewiss, was ein erhebliches Risiko darstellen kann.

Zur Verdeutlichung des Risikos eines fehlerhaften Formparameters soll dieses exemplarisch untersucht werden. Für ein Neuprodukt einer Fahrzeugkomponente soll das Zuverlässigkeitsziel folgendermaßen lauten:  $B_{10}=100.000\text{LW}$  bei einer Aussagewahrscheinlichkeit von 90%. Im Projektterminplan kann eine Testdauer von 75.000LW realisiert werden, vereinfacht wird in diesem Beispiel von ausreichenden Prüfstandskapazitäten ausgegangen.

Zusätzlich wird noch ein verschärftes Szenario bewertet, in dem nur 50.000LW je Prüfling zur Verfügung stehen. Beide Fälle sind als praxisrelevant einzustufen, wobei ein Lebensdauer Verhältnis von Prüfdauer zur Lebensdaueranforderung kleiner als 0,5 keine Seltenheit ist.

Bild 3 zeigt zunächst erste Szenario mit einer Prüfdauer von 75.000LW. In Abhängigkeit des Formparameters ist die erforderliche Prüflingsanzahl aufgetragen, die für den Nachweis des  $B_{10}$ -Wertes bei einer Aussagewahrscheinlichkeit von 90% erforderlich ist.

Wie bereits angemerkt, ist bereits in der Planungsphase ein Wert für den Formparameter  $b$  der Weibullverteilung notwendig, der aber nur aus Ausfalldaten bestimmt werden kann. Sollte die Einschätzung des Formparameters fehlerhaft sein, so folgt daraus unmittelbar eine fehlerhafte Prüflingsanzahl. Wird beispielsweise ein Formparameter mit 2,0 vermutet, in der Realität wird die Ausfallursache allerdings durch einen Formparameter von 3,5 beschrieben, so würde die Testplanung 21 zu wenige Prüflinge vorsehen.




Bild 3: Erforderliche Prüfungsanzahl für Szenario I einer ausfallfreien Testplanung

Die Auswirkungen dieser fehlerhaften Einschätzung des Formparameters bei der Planung eines ausfallfreien Tests zeigt Bild 4. Dort wird gezeigt, welche Auswirkungen auf die Aussagewahrscheinlichkeit die Einschätzung des Formparameters hat.




Bild 4: Aussagewahrscheinlichkeiten für Szenario I einer ausfallfreien Testplanung



Die Basis bilden 39 Prüflinge, die bei Szenario 1 das Zuverlässigkeitsziel für einen Formparameter von 2,0 nachweisen können. Sollte sich der Formparameter in der Realität von dieser Einschätzung unterscheiden, so müssten nach Bild 3 mehr Prüflinge ausfallfrei getestet werden. Da die Einschätzung des Formparameters aber nicht mit einem success run Nachweis überprüft werden kann, werden die Folgen aus Bild 4 eintreten, nämlich eine im Vergleich zur Anforderung zu geringe Aussagewahrscheinlichkeit. So ergibt sich für dieses Szenario bei einem realen Formparameter von 3,5 lediglich eine Aussagewahrscheinlichkeit von 78%.

In Szenario 2 steht weniger Zeit für die Lebensdauertests zur Verfügung, die Prüfdauer je Prüfling beträgt lediglich 50.000LW. Die Auswirkung der reduzierten Prüfdauer von Szenario 2 auf die erforderlichen Stichprobengrößen zeigt Bild 5.




Bild 5: Erforderliche Prüfungsanzahl für Szenario II einer ausfallfreien Testplanung

Sollte es in Szenario II zu einer fehlerhaften Einschätzung des Formparameters  $b$  kommen, so sind die daraus resultierenden Folgen für die Aussagewahrscheinlichkeit größer als bei Szenario I, siehe Bild 6. Sollte der Formparameter irrtümlich mit 2,0 statt 4,0 eingeschätzt worden sein, so halbiert sich die Aussagewahrscheinlichkeit von 90% auf einen bedenklichen Wert von 44%.




Bild 6: Aussagewahrscheinlichkeiten für Szenario II einer ausfallfreien Testplanung

Die Szenarios I und II zeigen die Folgen einer fehlerhaften Einschätzung des Formparameters  $b$  einer ausfallfreien Testplanung auf. In beiden Szenarios ist der Formparameter zu klein eingeschätzt. Selbstverständlich ist auch die Schätzung eines zu großen Formparameters möglich. Aus statistischer Sicht besteht dann kein erhöhtes zuverlässigkeitstechnisches Risiko, ganz im Gegenteil: die Prüflingsanzahl ist zu groß. Dies bedeutet allerdings ein wirtschaftliches Risiko, da unnötige Kosten verursacht werden. Die Auswirkungen eines zu groß eingeschätzten Formparameters sind ebenfalls in Bild 3 und Bild 5 zu entnehmen. Sollte für Szenario II ein Formparameter mit 4,0 abgeschätzt sein, in Realität liegt der Formparameter allerdings nur bei 2,0, so wäre statt eines Stichprobenumfangs von 350 Prüflingen bereits eine Stichprobengröße von 88 ausreichend. Es werden also fast viermal so viele Prüflinge getestet als dies notwendig wäre. Auch dieser Kosteneinfluss könnte zusätzlich in der Zuverlässigkeitskostenspirale in Bild 2 Berücksichtigung finden.

Die Szenariostudie soll verdeutlichen, dass es von enormer Wichtigkeit ist, zu Beginn v.a. einer ausfallfreien Testplanung eine treffsichere Schätzung eines Formparameters  $b$  sicherzustellen. Zusätzlich sollte dieser Formparameter möglichst hinterfragt werden, indem ausfallorientierte Test durchgeführt werden. So kann beispielsweise ein ausfallfreier Test für die Freigabe einer Musterphase verwendet werden. Nach dieser Freigabe kann der ausfallfreie Test bis zu

einer ausreichenden Anzahl an Ausfällen fortgesetzt werden. Diese zensierte Stichprobe ermöglicht dann eine Bestätigung des geschätzten Formparameters der Testplanung für den success run Nachweis.

Die während eines Produktentwicklungsprojektes gewonnenen Erkenntnisse müssen fortlaufend in die Planung und Bewertung der bereits durchgeführten Tests, aber auch der noch stattfindenden Tests der weiteren Produktentwicklung, einfließen. Ziel muss es immer sein, Annahmen zu hinterfragen und ggf. fehlerhafte Annahmen zu überprüfen und bei Bedarf revidieren zu können.

### 3. Zusammenfassung

Die Definition eines Zuverlässigkeitsziels ist in der Praxis oftmals mit Herausforderungen verbunden. Die Basis für eine geeignete Zieldefinition bilden Kenntnisse und Erfahrungen der Zuverlässigkeitsmethoden in Kombination mit der Verfügbarkeit einer geeigneten Datenbasis. Die Daten gilt es immer kritisch zu hinterfragen, u.a. im Kontext der Kundengewohnheiten. Die größte praktische Herausforderung der Zieldefinition besteht meist in der Festlegung der Systemzuverlässigkeit, für die Ableitung auf untergeordnete Produktebenen bestehen zahlreiche methodische Ansätze [7].

Die Testplanung zum Nachweis der Produktzuverlässigkeit kann erst dann zielgerichtet gestartet werden, wenn ein geeignetes Zuverlässigkeitsziel vorhanden ist. Die Planung eines success run Tests erscheint zunächst sehr einfach, da mit wenigen Daten die erforderliche Prüflingsanzahl berechnet werden kann. Der Beitrag zeigt die Bedeutung des Formparameters  $b$  der Weibullverteilung für derartige Testplanungen auf und illustriert mögliche Auswirkungen einer Fehleinschätzung des Formparameters anhand zweier Szenarien. Ein Lösungsansatz kann ein verlängerter Lebensdauertest sein, der zunächst als ausfallfreier Test geplant und ausgewertet wird, dann aber zu einem ausfallorientierten Lebensdauertest zur Bestätigung des angenommenen Formparameters  $b$  verlängert wird.

Die gezeigten Herausforderungen der angewandten Zuverlässigkeitstechnik sind nur einige wenige Praxisbeispiele. Meist sind Lösungswege sehr spezifisch auf die jeweiligen Randbedingungen zugeschnitten und können deshalb nicht immer auf andere Anwendungsfälle sofort übertragen werden. Die gezeigten Inhalte sollen Ideen zum Umgang praktischer Herausforderungen der Zuverlässigkeitstechnik liefern und grundsätzliche Abhängigkeiten aufzeigen.

#### 4. Literaturverzeichnis

- [1] Bertsche, B.; Lechner, G.: Zuverlässigkeit im Fahrzeug- und Maschinenbau. 3. Aufl., Springer Verlag, 2004.
- [2] Dazer, M.; Bräutigam, D.; Leopold, T.; Bertsche, B.: Optimal Planning of Reliability Life Tests Considering Prior Knowledge. 2018 Annual Reliability and Maintainability Symposium (RAMS), Reno, NV, 2018.
- [3] Dazer, M.: Zuverlässigkeitstestplanung mit Berücksichtigung von Vorwissen aus stochastischen Lebensdauerberechnungen. Dissertation, Berichte aus dem Institut für Maschinenelemente, Bericht Nr. 190, 2019.
- [4] Leopold, T.: Ganzheitliche Datenerfassung für verbesserte Zuverlässigkeitsanalysen. Dissertation, Berichte aus dem Institut für Maschinenelemente, Bericht Nr. 140, 2012.
- [5] Meyna, A.; Pauli, B.: Taschenbuch der Zuverlässigkeitstechnik. 2. Aufl., Hanser Verlag, 2010.
- [6] Schubert, R.; Haller, S.; Pasch, F.: Hochwertig – aber auch zuverlässig? In: Qualität und Zuverlässigkeit (2016), Nr. 5, S. 44-47.
- [7] VDA Band 3.2: Zuverlässigkeitssicherung bei Automobilherstellern und Lieferanten. Zuverlässigkeits-Methoden und -Hilfsmittel, Heinrich Druck + Medien GmbH, 2016.

# Bestimmung der Systemzuverlässigkeit unter Berücksichtigung der Systemstruktur und Einbindung von Vorwissen

M.Sc. **S. Lämmle**, Dipl.-Ing. **P. Kupfer**,  
ZF Friedrichshafen AG, Friedrichshafen;  
Dr. **S. Feth**, Dr. **J. Fiedler**,  
Fraunhofer-Institut für Techno- und Wirtschaftsmathematik,  
Kaiserslautern

## Kurzfassung

Bei der Berechnung der Systemzuverlässigkeit tauchen serielle und parallele Verschaltungen von Elementen auf. Auf Basis von Betaverteilungen war die Berechnung bisher nur für Systeme, deren Elemente seriell geschaltet sind möglich [1]. In Folge konnte bei parallelen Verschaltungen mit Betaverteilungen keine Aussage mit Konfidenz getroffen werden. Weiterhin ist die Systemzuverlässigkeit von betaverteilten Einzelzuverlässigkeiten selbst nicht exakt betaverteilt. Dieser Beitrag stellt deshalb eine Methode vor, um beliebige Verschaltungen in der Zuverlässigkeitsbetrachtung zu berücksichtigen. Dazu wird die Momentenmethode auf parallele und gemischte Systeme erweitert und auf der Systemebene die Poly-Betaverteilung eingeführt. Auf Basis des Satz von Bayes kann auf jeder Systemebene Vorwissen als Betaverteilung eingebracht werden. Nicht quantifizierbare Fehlermechanismen werden über Sensitivitäten und FMEA-Bewertungen abgeschätzt.

## 1. Einführung und Problemstellung

Die Zuverlässigkeitsplanung spielt eine zentrale Rolle in der Produktvalidierung, um ein angestrebtes Qualitätsniveau sicherzustellen. Von Interesse ist die Zuverlässigkeit des Gesamtprodukts auf Basis seiner Subsysteme und Komponenten. Statistische Methoden können dazu Unsicherheiten aus der begrenzt zur Verfügung stehenden Prototypenzahl berücksichtigen. Die nachgewiesene Zuverlässigkeit wird um die Konfidenz (Aussage-wahrscheinlichkeit) ergänzt. Um die Verteilung der Zuverlässigkeit mathematisch zu beschreiben überführt die Boole'sche Theorie die Zuverlässigkeiten einzelner Komponenten in seriellen oder parallelen Schaltungen zur Systemzuverlässigkeit.

## Betaverteilungen modellieren die Zuverlässigkeit

Die Zuverlässigkeit  $R$  ist als Prozentwert im Intervall  $[0, 1]$  definiert. Um das Wissen über die Zuverlässigkeit zu modellieren, kann eine statistische Verteilung, die auf diesen Bereich definiert ist, verwendet werden. Hierfür eignen sich besonders Betaverteilungen wegen ihrer hohen Flexibilität in der Modellierung. Weiterhin lassen sie sich analytisch gut kombinieren und mit den Daten (aktueller Versuch) zu aktualisiertem Wissen verrechnen. Diesen Aspekt betrachten wir in Abschnitt 3 genauer.

Betaverteilungen sind durch zwei positive Parameter  $A$  und  $B$  definiert und haben folgende Dichtefunktion:

$$f(R) = \frac{1}{\text{Beta}(A,B)} R^{A-1} (1-R)^{B-1}, \quad 0 \leq R \leq 1; A, B > 0, \quad (1)$$

mit der sogenannten Betafunktion  $\text{Beta}(\cdot)$ .




Bild 1: Dichtefunktion einer Betaverteilung, mit der Konfidenz  $C$  als Fläche unter der Dichtefunktion für die Zuverlässigkeit  $R_C$

Der Parameter  $A$  wird auch Pseudo-Durchläuferzahl genannt. Je größer der Wert, desto mehr Durchläufer wurden bis zur Prüfdauer erreicht. Der Parameter  $B$  zählt als Pseudo-Ausfallzahl entsprechend die Ausfälle. Das Integral über die Dichtefunktion liefert die modellierte Zuverlässigkeit  $R_C$  mit Konfidenz  $C$ :

$$C = \int_{R_C}^1 \frac{1}{\text{Beta}(A,B)} R^{A-1} (1-R)^{B-1} dR \quad (2)$$

## Systemzuverlässigkeit – “Klassische” Lösung

Der klassische Ansatz ermittelt die Zuverlässigkeit eines Systems über Boole'sche Logik [2].




Bild 2: Beispiel eines gemischten Systems

So führt etwa das System aus Bild 2 zu folgender Gleichung:

$$R_S(t) = R_{FM1}(t) \cdot R_{FM2}(t) \cdot \left(1 - (1 - R_{FM3}(t)) \cdot (1 - R_{FM4}(t))\right) \quad (3)$$

Hierbei werden keinerlei Konfidenzen berücksichtigt und es ist unklar, wie sicher die ausgegebene Systemzuverlässigkeit ist. Modelliert man hingegen Fehlermechanismen (kurz FM) mit Betaverteilungen, so können Konfidenzinformationen abgeleitet werden. Dabei überträgt zunächst die Momentenmethode [1, 2] die Betaverteilungen der Fehlermechanismen auf eine Betaverteilung des Systems. Dieser Ansatz birgt zwei Herausforderungen:

- 1) Er ist zunächst nur für serielle Subsysteme formuliert.
- 2) Serielle Verschaltungen von Betaverteilungen sind nicht exakt betaverteilt.

Es fehlt ein durchgängiger, analytisch-korrekter Ansatz, um die Zuverlässigkeit eines gemischten Systems mit Konfidenz zu bestimmen.

## 2. Bestimmung der Systemzuverlässigkeit

Kundenanforderungen an die Zuverlässigkeit beziehen sich meistens auf die Systemebene des Produkts. Um die Zuverlässigkeit auf dieser Ebene zu bestimmen, müssen die Informationen auf unterster Ebene (FM) bis hin zur obersten Systemebene miteinander verknüpft werden.

### Systemzuverlässigkeit – Herausforderungen bei der Bestimmung

Reale Systeme enthalten seriell und parallel verschaltete Systemelemente. So werden beispielsweise in der Elektronik Elemente parallel geschaltet, um Redundanzen zu erhalten.

Ansätze, um Vorwissen in die Systemzuverlässigkeit mit Konfidenz einzubinden, müssen auf diese beiden Verschaltungen eingestellt sein.

Sollen möglichst alle FM berücksichtigt werden, stößt man schnell auf eine Vielzahl nicht oder nur schwer quantifizierbarer FM. Hier muss eine plausible Vorgehensweise gefunden werden, um deren Zuverlässigkeit zu schätzen.

### Bestimmung der Systemzuverlässigkeit

Die Zuverlässigkeit eines Systems kann iterativ bestimmt werden:

- 1) Allen Fehlermechanismen werden Betaverteilungen zugeordnet.
- 2) Identifiziere reine serielle oder parallele Verschaltungen auf den Ebenen des Systems und bestimme eine (betaverteilte) Ersatzkomponente. Wiederhole diesen Schritt so lange, bis auf Systemebene eine reine serielle oder parallele Verschaltung vorliegt.
- 3) Bestimme eine Poly-Betaverteilung auf oberster Systemebene.

Der Ablauf wird am exemplarischen System aus Bild 3 verdeutlicht. FM4 und FM5 bilden ein serielles Subsystem, für das die Momentenmethode eine betaverteilte Ersatzkomponente FM6 bestimmt.




Bild 3: Gemischtes System

Die Zuverlässigkeit von FM6 ist nicht exakt betaverteilt, jedoch ist die Abweichung eher gering. Ihre Beta-Parameter  $A, B$  werden derart ermittelt, dass der Erwartungswert (erstes Moment) und das zweite Moment von FM6 gerade den Produkten der ersten und zweiten Momente der Komponenten FM4 und FM5 entsprechen. Resultat ist die Ersatzkomponente FM6 mit Parameter  $A = 64,60$  und  $B = 1,47$ .




Bild 4: Gemischtes System, mit Ersatzkomponente FM6

Im nächsten Iterationsschritt liegt ein reines Parallelsystem aus FM3 und FM6 vor. Hierfür wird eine Modifikation der Momentenmethode verwendet. In rein parallelen Systemen ist die



Ausfallwahrscheinlichkeit das Produkt der Ausfallwahrscheinlichkeiten der Subsysteme. Das verhält sich analog zu rein seriellen Systemen, wo sich die Zuverlässigkeiten multiplikativ verhalten.

Wird eine Zuverlässigkeit durch eine Betaverteilung  $\beta(A, B)$  mit Parametern  $A$  und  $B$  modelliert, so ist die Ausfallwahrscheinlichkeit betaverteilt  $\beta(B, A)$  mit vertauschten Parametern  $A$  und  $B$ . Für parallel-geschaltete Komponenten ergibt sich als Vorgehen:

- 1) Vertausche für jede Komponente die Parameter  $A$  und  $B$ .
- 2) Wende die Momentenmethode für seriell-geschaltete Komponenten an.
- 3) Vertausche die Parameter  $A$  und  $B$  des Resultates aus der Momentenmethode.

Resultat ist die Ersatzkomponente FM7 mit Parameter  $A = 64,60$  und  $B = 1,47$ .




Bild 5: Gemischtes System, mit Ersatzkomponente FM7

Die Parameter von FM7 haben sich gegenüber FM6 kaum verändert. Ursache ist, dass FM6 in einer parallelen Schaltung die weniger zuverlässige Komponente FM3 dominiert.

Final ergibt sich ein serielles System mit den Komponenten FM1, FM2 und FM7. Im letzten Iterationsschritt wird die Momentenmethode nicht verwendet, weil die serielle Verschaltung von Betaverteilungen nicht exakt in einer Betaverteilung resultiert [3]. Stattdessen wird zu einer numerischen Approximation der wahren Verteilung gewechselt (durch Monte-Carlo-Simulation).




Bild 6: Approximationsfehler, wenn das gesamte System mit der Momentenmethode (rote Kurve) bestimmt wird gegenüber der Poly-Beta-Verteilung (schwarzes Histogramm)

Bild 6 zeigt, dass der Approximationsfehler auf Systemebene einen einstelligen Prozentpunktfehler ausmachen kann. Auf Subsystemebene hingegen haben unsere Untersuchungen gezeigt, dass die Approximation durch die Momentenmethode sich numerisch vernachlässigbar auf das Ergebnis niederschlägt.

Auf Lebensdauerebene ergeben mehrere serielle Weibullverteilungen (für die FM) eine Poly-Weibullverteilung [4] für das System. In Anlehnung daran wird die Zuverlässigkeitsverteilung eines seriellen Systems als Poly-Beta-Verteilung bezeichnet.

### Berücksichtigung von nicht quantifizierbaren Komponenten

Im Fokus einer Systemzuverlässigkeitsanalyse stehen häufig verschleiß- und ermüdungsbedingte Versagensmechanismen. Das Ausfallverhalten aller FM ist nur selten bekannt.

Falls keine quantifizierte Ausfallstatistiken zur Verfügung stehen, können Hersteller zumindest auf qualitative Analysen zurückgreifen. In FMEA's wird neben der Bedeutung eines Fehlers (B) und seiner Entdeckungsmöglichkeit (E) auch seine Auftretenshäufigkeit (A) eingeschätzt. In [5] wird beschrieben, wie in einer FMEA die Auftretenshäufigkeiten (A-Kennzahl) einer Versagensart in eine Ausfallwahrscheinlichkeit bzw. Zuverlässigkeit überführt werden kann. Diese Einschätzung führt in zwei Schritten zu einer Bewertung der nicht quantifizierten Komponenten:

- 1) Sensitivitäten nicht quantifizierbarer Fehlermechanismen ermitteln.
- 2) Nicht bezifferte Versagensmechanismen anhand ihrer FMEA-A-Kennzahl überprüfen.

Die geforderte Mindestzuverlässigkeit wird ermittelt, indem zuerst die Zuverlässigkeit eines Systems bestimmt wird, in welchem die nicht quantifizierten FM entfernt wurden. Anschließend wird berechnet, wie gut diese mindestens sein müssten, damit sich die Systemzuverlässigkeit nicht um mehr als einen definierten Wert (z.B. 1%) von der zuvor berechneten unterscheidet. Der so berechnete Schwellwert kann dann in eine FMEA A-Kennzahl überführt werden. Liegen die A-Kennzahlen oberhalb dieses Schwellwerts, beeinflussen sie die Systemzuverlässigkeit kaum und können vernachlässigt werden.

Tabelle 1: FMEA, Auftretenswahrscheinlichkeit aus [5]

A-Kennzahl	1	2	3	4	5	6	7	8	9	10
ppm	1	50	100	1.000	2.000	5.000	10 <sup>4</sup>	2*10 <sup>4</sup>	5*10 <sup>4</sup>	10 <sup>5</sup>
Ausfallw. P	10 <sup>-6</sup>	5*10 <sup>-5</sup>	10 <sup>-4</sup>	10 <sup>-3</sup>	2*10 <sup>-3</sup>	5*10 <sup>-3</sup>	0,01	0,02	0,05	0,1

Folgende Formel überführt A-Kennzahlen in eine Betaverteilung:

$$A = \frac{R}{1-R}, \quad B = 1 \quad (4)$$

Hierbei ist  $R$  die Zuverlässigkeit, welche sich bei der entsprechenden A-Kennzahl aus  $R = 1 - P$  ergibt.  $A$  und  $B$  sind dann die resultierenden Parameter der Betaverteilung.

### 3. Einbindung von Vorwissensquellen

In der Praxis wird die Zuverlässigkeit oftmals über eine physikalische Erprobung des Produkts nachgewiesen. Basis ist häufig die sogenannten Success-Run-Strategie. Hierbei läuft der Versuch nicht bis zum Ausfall, sondern bis zu einer definierten Prüfdauer  $t_s$ :

$$n_{SR} = \frac{\ln(1-C)}{\ln(R(t_s))} \quad (5)$$

Ist eine hohe Zuverlässigkeit  $R$  (mit Konfidenz  $C$ ) gefordert, so ist ein großer Stichprobenumfang  $n_{SR}$  für den statistischen Nachweis nötig. Um die Anzahl der Tests und die damit verbundenen Kosten zu senken, können Vorwissensquellen (z.B. Berechnungsergebnisse) mit dem bestehenden Wissen (aktuelle Validierungstests) verknüpft werden.

Berücksichtigt man die Systemstruktur und Fehlermechanismen umfänglich, gelingt der geforderte Nachweis der Systemzuverlässigkeit auf Basis einer Success-Run-Strategie oft nicht. Dann hilft es, Vorwissen zu verwenden. Oft können erst durch die Verwendung von Vorwissensquellen die Ziele statistisch nachgewiesen werden.

## Vorwissen auf verschiedenen Ebenen des Systems

Die Systemzuverlässigkeit wird durch logische Verknüpfung der Struktur, vom FM bis hin zur Systemebene (TOP-Element), bestimmt (siehe Abschnitt 2). Dabei wird die jeweilige Zuverlässigkeitsverteilung der Systemelemente über eine Betaverteilung beschrieben (siehe Bild 7). Eine Ausnahme hiervon bildet das Top-Element als Poly-Betaverteilung.

Werden in Validierungstests ganze Baugruppen als Success Run abgetestet, so können resultierende Ergebnisse nicht immer bis auf FM-Ebene heruntergebrochen werden. Dennoch soll dieses Wissen (z.B. aus Success Runs) auf der entsprechenden Ebene einfließen können.

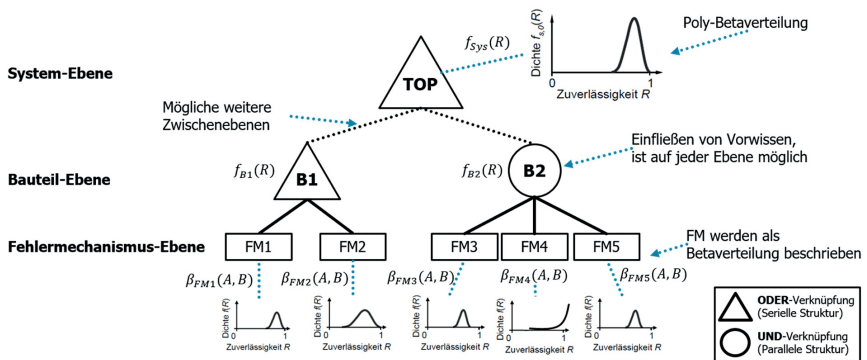


Bild 7: Vorwissenquellen auf verschiedenen Ebenen des Systems

Die Systemzuverlässigkeit wird prinzipiell wie in Kapitel 2 erläutert bestimmt. Jedoch wird auf den jeweiligen Ebenen das Vorwissen (falls vorhanden) als Verteilung berücksichtigt. Zuerst werden die Zuverlässigkeitsverteilungen auf unterster Ebene (FM) durch Kombination des Vorwissens mit aktuellen Tests bestimmt. Die daraus resultierende Verteilung dient dann als Eingangsgröße für die Berechnung auf der nächsthöheren Ebene wo die Berechnung in zwei Schritten durchgeführt wird:

- 1) Kombination der darunterliegenden Elemente, über die Momentenmethode, entsprechend der Verknüpfungsart (seriell/parallel)
- 2) Verknüpfung von Vorwissen mit der Verteilung aus den darunterliegenden Elementen

Analog dazu können die Ebenen bis zum Top-Element aufgelöst werden.

## Einbindung von Vorwissensquellen – Herausforderungen und Ansatz

Um Vorwissen zu verwenden müssen diverse Quellen in ein einheitliches Verteilungsformat überführt werden:

- Physikalische Tests aus Vorgängerprodukten oder ähnlichen Produkten
- Berechnungen mit unbekannten Versuchspunkten (z.B. Berechnung nach Norm)
- Berechnung mit bekannten Versuchspunkten (z.B. validierte Berechnungsmodelle)
- Felddaten
- Auftretenswahrscheinlichkeit aus FMEA

Ein Ansatz besteht darin, die Vorwissensquelle  $f_{prior}(R)$  (a-priori-Dichte) mit der Verteilung aus den Tests  $f(x_i|R)$  über den Satz von Bayes [6] zu einer a posteriori Dichte  $f_{post}(R)$  zu verbinden:

$$f_{post}(R) = \frac{f(x_i|R) * f_{prior}(R)}{\int_0^1 f(x_i|R') * f_{prior}(R') dR'} \quad (6)$$

Die a posteriori-Dichte liefert eine genauere Einschätzung der Zuverlässigkeit (siehe Bild 8).

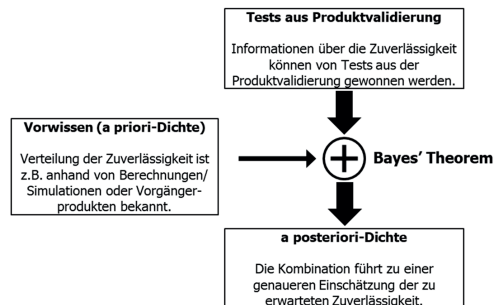


Bild 8: Satz von Bayes

Verwendet man die Betaverteilungen durchgängig, so vereinfacht sich der Satz von Bayes. Liegen z.B. Produktvalidierungstest ohne Ausfälle als Success Run vor, so ergibt sich:

$$A_{post} = \sum_{i=0}^n \Phi_i A_{prior,i} + n_{SR} * L_v^b \quad (7)$$

$$B_{post} = \sum_{i=0}^n \Phi_i(B_{prior,i} - 1) + 1 \quad (8)$$

$A_{post}, B_{post}$  sind hier die Parameter der a-posteriori Betaverteilung, und  $A_{prior,i}, B_{prior,i}$  die Parameter der Betaverteilungen der  $n$  Vorwissensquellen. Zudem ist  $n_{SR}$  der Stichprobenumfang des Success Runs und  $L_v$  das Lebensdauerverhältnis mit dem Formparameter  $b$  der Weibullverteilung. Mit dem Transformationsfaktor  $\Phi_i \in [0, 1]$  kann das Vorwissen gewichtet eingebracht werden. Für weitere Informationen siehe [7, 8].

### Überführung von Lebensdauerdaten in Vorwissen

Exemplarisch wird hier die Überführung von Vorwissen aus physikalischen Tests mit Ausfällen erläutert. An die Ausfalldaten wird zunächst eine Lebensdauerverteilung, z.B. Weibull, angepasst. Zur angepassten Lebensdauerverteilung kann dann die Zuverlässigkeit bzgl. einer Ziellebensdauer/-schädigung abgelesen werden. Bild 9 zeigt dies für die Zielschädigung  $D^* = 0,5$  (rote vertikale Linie). Die mittlere abgelesene Ausfall-wahrscheinlichkeit ist ca. 0,05 bis 0,1 was einer Zuverlässigkeit von 90% bis 95% entspricht. Wegen des begrenzten Stichprobenumfangs ist die Aussage mit einer Konfidenz behaftet; dargestellt durch eine Kurvenschaar. Schließt man mit einem Bootstrap-Verfahren alle Schnitte der vertikalen roten Linie mit der Kurvenschaar in die Konfidenzbetrachtung ein, so ergibt sich die Betaverteilung auf der rechten Seite von Bild 9. In [9] ist z.B. dargestellt, wie Vorwissen aus Lebensdauerberechnungen in eine Betaverteilung überführt wird.




Bild 9: Weibullverteilungen aus Bootstrap (links) und sich ergebende Betaverteilung für Schädigung  $D^* = 0,5$  (rechts)



Tabelle 2: Beispiel *Gearbox* mit Vorwissen

Name	Typ	A <sub>test</sub>	B <sub>test</sub>	A <sub>prior</sub>	B <sub>prior</sub>	A <sub>post</sub>	B <sub>post</sub>	Reliability (C=90%)
Gearbox	TOP	-	-	-	-	-	-	0,86
Gear 1	SUB	-	-	-	-	143,98	1,74	0,97
Gear 2	SUB	-	-	-	-	37,81	2,04	0,90
Ball Bearing 1	SUB	-	-	-	-	71,37	0,82	0,97
Ball Bearing 2	SUB	-	-	-	-	58,84	0,44	0,97
Seal	SUB	-	-	-	-	199,00	1,00	0,98
Gear1 – Pitting	FM	1562,75	1,00	-	-	1562,75	1,00	0,99
Gear1 – Fatigue	FM	367,68	1,00	-	-	367,68	1,00	0,99
Gear1 – Wear	FM	114,63	1,00	-	-	114,63	1,00	0,98
BB1 – Pitting*	FM	15,81	1,00	32,98	0,36	48,79	0,36	0,97
BB1 – Fatigue*	FM	1466,74	1,00	30,87	0,40	1497,61	0,40	0,99
BB1 – Wear*	FM	347,82	1,00	16,01	1,40	363,83	1,40	0,99
BB2 – Pitting*	FM	1630,05	1,00	11,40	0,23	1747,45	0,23	0,99
BB2 – Fatigue*	FM	20,11	1,00	32,98	0,36	53,09	0,36	0,98
BB2 – Wear*	FM	577,15	1,00	30,85	0,40	608,00	0,40	0,99
Gear2 – Pitting	FM	38,45	1,00	-	-	38,45	1,00	0,94
Gear2 – Fatigue	FM	37,39	1,00	-	-	37,39	1,00	0,94
Gear2 – Wear	FM	1756,43	1,00	-	-	1756,43	1,00	0,99
Seal - Wear	FM	-	-	199,00	1,00	199,00	1,00	0,98

#### 4. Zusammenfassung und Fazit

In diesem Beitrag wird ein Ansatz vorgestellt, um die Zuverlässigkeit von gemischten Systemen zu bestimmen. Mit Hilfe von Beta- und Poly-Betaverteilungen ist eine eindeutige Verbindung zwischen Zuverlässigkeit und Konfidenz möglich. Bislang nicht quantifizierbare FM können in der Methode über Sensitivitäten und FMEA-Bewertungen abgeschätzt werden.

In der Praxis zeigt sich häufig, dass die Zuverlässigkeitsziele über Versuche, bei umfänglicher Berücksichtigung von Systemstruktur und Fehlermechanismen, nicht mit vertretbarem Aufwand erreicht werden können. Mittels des Satz von Bayes können auf den verschiedenen Systemebenen Vorwissensquellen das Ergebnis verbessern. Dadurch ist es möglich, den Erprobungsaufwands zu reduzieren.



## 5. Literatur

- [1] Maisch, M.: Zuverlässigkeitsorientiertes Erprobungskonzept für Nutzfahrzeuggetriebe unter Berücksichtigung von Betriebsdaten, Dissertation, Universität Stuttgart, 2007
- [2] Bertsche, B.; Lechner, G.: *Zuverlässigkeit im Fahrzeug und Maschinenbau*. 3. Aufl.: Springer-Verlag 2004 – ISBN 3540208712
- [3] Springer, M.; Thompson, W.: The distribution of products Beta, Gamma and Gaussian random variables. In: *SIAM Journal on Applied Mathematics* Bd. 18 (1970), Nr. 4, S. 721-737
- [4] Berger, J.; Sun, D.: Bayesian Analysis for the Poly-Weibull Distribution. In: *Journal of the American Statistical Association* Bd. 88 (1993)
- [5] Verband der Automobilindustrie: Qualitätsmanagement in der Automobilindustrie, Teil 3: Zuverlässigkeitssicherung bei Automobilherstellern und Lieferanten. VDA, 2018
- [6] Bayes, T.; Price, R.: An Essay Towards Solving a Problem in the Doctrine of Chances. By the Late Rev. Mr. Bayes, F. R. S. Communicated by Mr. Price, in a Letter to John Canton, A. M. F. R. S. In: *Philosophical Transactions of the Royal Society of London* Bd. 53 (1763), Nr. 0, S. 370-418 – ISBN 02607085
- [7] Krolo, A.: Planung von Zuverlässigkeitstests mit weitreichender Berücksichtigung von Vorkenntnissen, Dissertation, Universität Stuttgart, 2004
- [8] Hitziger, T.: Übertragbarkeit von Vorkenntnissen bei der Zuverlässigkeitstestplanung, Dissertation, Universität Stuttgart, 2007
- [9] Grundler, A., Bollmann, M., Obermayr, M., Bertsche, B.: Berücksichtigung von Lebensdauerberechnungen als Vorkenntnis im Zuverlässigkeitsnachweis. In: *Tagung Technische Zuverlässigkeit* 2019 Bd. 2345 (2019): VDI



# Empirische Lebensdauerprädiktion von Elektrolytkondensatoren in hochbeanspruchten Applikationen elektrifizierter Fahrzeuge

M.Sc. **Philipp Adler**, Volkswagen Group Components, Salzgitter

## Kurzfassung

Durch die Elektrifizierung des Automobils erhalten elektrisch angetriebene Nebenaggregate zusätzliche Aufgaben neben dem eigentlichen Fahrbetrieb wie beispielsweise das Kühlen der Hochvoltbatterie während des Ladevorgangs. Eine der Hauptausfallursachen dieser Komponenten ist der Elektrolytkondensator im Zwischenkreis der eingebauten Leistungselektronik. Um sicherzustellen, dass die Zuverlässigkeit der Zwischenkreis-kondensatoren in einem elektrischen Kältemittelverdichter über eine Fahrzeuglebensdauer von 15 Jahren gewährleistet ist, wird eine Multi-Domänen-Simulation vorgestellt. Diese Simulation verknüpft verschiedene physikalische Disziplinen miteinander, um die Alterung der Kondensatoren in verschiedenen Regionen der Erde abzuschätzen. Somit kann bereits während der Entwicklungsphase die Zuverlässigkeit unter verschiedenen Szenarien untersucht werden, und ggf. Abhilfemaßnahmen getroffen werden.

## 1. Einleitung

Die Zuverlässigkeit von Fahrzeugen zählt zu den wichtigsten Kriterien von Kunden beim Kauf eines Neu- und Gebrauchtwagens [1, 2, 3]. Abbildung 1 stellt die Kaufkriterien von deutschen Kunden der Jahre 2001, 2015 und 2017 gegenüber. Ersichtlich ist, dass der Stellenwert der Zuverlässigkeit überragt und über die Jahre weiter zugenommen hat.




Bild 1: Kriterien beim Neuwagenkauf aus den Jahren 2001, 2015 und 2017 [1,2,3].

Folglich muss sichergestellt werden, dass die im Fahrzeug verbauten Komponenten die typischen 15 Jahre Fahrzeuglebenszeit erreichen [4], ohne eine Überdimensionierung der verwendeten Bauteile und somit erhöhten Kosten für den Kunden zu erzeugen.

Durch den Entfall des Keilriemens bei Elektrofahrzeugen werden die elektrischen Nebenaggregate wie Wasserpumpen, Klimakompressor etc. durch die Fahrzeug-batterie mit Energie versorgt. Je nach erforderlicher Leistung werden die Komponenten durch die 12 V-Batterie oder die Hochvolt-Batterie betrieben. Um die Gleichspannung der Batterien in eine dreiphasige Wechselspannung zur Regelung eines Motors umzuwandeln, ist ein Wechselrichter notwendig. Dieses leistungselektronische System ist meist durch mehrere Meter Leitungslängen von der Energiequelle getrennt, sodass eine Zwischenkreiskapazität innerhalb des Wechselrichters für ein Stützen der Spannung erforderlich ist. Ohne diesen lokalen Energiespeicher würde die Spannung bei Leistungsentnahme unzulässig abnehmen. Der elektrische Kältemittelverdichter mit R744 (CO<sub>2</sub>) als Kältemittel hat eine Leistung von 7 kW bei einer HV-Batteriespannung von 450 V, sodass für die Zwischenkreiskapazität Folien- oder Elektrolytkondensatoren eine geeignete Wahl darstellen. Elektrolytkondensatoren zeichnen sich vor allem durch ihre geringen Kosten und sehr hohen Volumenkapazität aus, wodurch auch der Bauraum dieser kleiner ist als bei Folienkondensatoren der gleichen Kapazität [5, 6]. Allerdings gelten die Kondensatoren hinsichtlich Zuverlässigkeit als eines der schwächsten Bauelemente in leistungselektronischen Systemen [7]. Insbesondere der Elektrolyt-kondensator wird dabei als kritischstes Bauteil angesehen [8]. Um den Betrieb des Verdichters über die gesamte Fahrzeuglebenszeit zu gewährleisten und somit die Batteriekühlung, die Enteisung der Frontscheibe, den Fahrkomfort u.v.m. sicherzustellen, muss die Alterung der Elektrolytkondensatoren betrachtet werden. Hierfür werden zunächst die Hauptalterungsursachen dieser Bauteile in Abschnitt 2 beschrieben, anschließend wird das Konzept der Zuverlässigkeitssimulation vorgestellt. In Abschnitt 4 wird die Simulation empirisch parametrisiert. Abschließend werden die Ergebnisse dargestellt, diskutiert und ein Fazit gezogen.

## 2. Ausfallursachen von Elektrolytkondensatoren

Ein Aluminium-Elektrolytkondensator mit flüssigem Elektrolyten besteht aus zwei Aluminiumfolien. I.d.R. handelt es sich bei diesem Bauteil um einen gepolten Kondensator, so dass eine Anoden- und eine Kathodenfolie bzw. Plus- und Minus-Pol existieren. Die Anodenfolie ist stark aufgeraut bzw. geätzt, wodurch die Fläche der Elektrode erhöht wird. Zudem besitzt diese eine künstliche Aluminiumoxidschicht, deren Dicke in der Formierung des Herstellungsprozesses je nach gewünschter Spannungsfestigkeit erzeugt wird. Durch die hohe Spannungsfestigkeit

von Aluminiumoxid kann diese Dielektrikumsschicht extrem dünn sein und beträgt bei Hochvolt-Kondensatoren unter 500 nm [9]. Dieser geringe Plattenabstand erzeugt die vergleichsweise hohe Kapazität des Aluminium-Elektrolytkondensators. Zusätzlich fügt sich der flüssige Elektrolyt passgenau an die Oxidschicht an, sodass die effektive Fläche des Kondensators ebenfalls groß ist. Dieser Elektrolyt bildet die eigentliche Kathode des Kondensators und ist in Papier getränkt. Das Papier erfüllt noch eine weitere Aufgabe, indem dieses als Separator einen Kontakt der Anoden- und der Kathodenfolie verhindert. Die Kathodenfolie dient lediglich zur Kontaktierung des Elektrolyten und verfügt über eine Lufoxidschicht, welche sich von Natur aus an Aluminium ausbildet. Abbildung 3 zeigt den schematischen Aufbau eines Elektrolytkondensators. Für eine detailliertere Darstellung des Bauteils wird auf die Literatur verwiesen [9, 10].




Bild 3: Der schematische Aufbau eines Elektrolytkondensators mit flüssigem Elektrolyt.

Neben der Kapazität eines Kondensators ist eine weitere Kenngröße dieses Bauteils der Innenwiderstand bzw. der äquivalente Serienwiderstand (engl. Equivalent Series Resistor, kurz ESR). Dieser Innenwiderstand ist zu einem Großteil durch die Leitfähigkeit des Elektrolyten bestimmt, welcher stark von der Temperatur des Bauteils abhängig ist [8]. Da die Energiespeicherung auf Ladungstrennungen von Ionen im Elektrolyten basiert, wird dieser Innenwiderstand durch die Viskosität der Flüssigkeit bestimmt. Diese Viskosität ist bei kalten Temperaturen höher, wohingegen diese bei hohen Temperaturen abnimmt. Folglich steigt die Leitfähigkeit mit höheren Temperaturen durch die bessere Ionenbeweglichkeit, und der ESR nimmt ab. Gleichzeitig steigt die Kapazität bei hohen Temperaturen, da die effektive Fläche des Kondensators zunimmt und der dünnflüssigere Elektrolyt auch tiefe Poren der Oxidschicht erreicht. Der Elektrolytkondensator besitzt eine Vielzahl von Alterungsmechanismen, welche von den Herstellern aufgelistet und grafisch dargestellt werden [11, 12, 13]. Innerhalb der Applikation ist die Alterung des Bauteils allerdings auf die Temperatur  $T$ , den Wechselstrom bzw. Ripplestrom

$I_{\text{rms}}$  und die elektrische Spannung  $U$  zu begrenzen. Folgender Ansatz hat sich zur Abschätzung der Lebensdauer von Elektrolytkondensatoren bewährt:

$$\frac{L}{L_0} = 2^{\frac{T_0 - T}{10 K_T}} \cdot \frac{K_i \left[ 1 - \left( \frac{I_{\text{rms}}}{I_{\text{rms},0}} \right)^2 \right]^{\frac{\Delta T_0}{10 K_R}}}{K_R} \cdot \left( \frac{U}{U_0} \right)^{-n} \quad (1)$$

Wird der Kondensator bei Nenntemperatur  $T_0$ , Nennspannung  $U_0$  und dem spezifizierten Ripplestrom  $I_{\text{rms},0}$  betrieben, so entspricht die zu erwartende Lebensdauer  $L$  der im Datenblatt angegebenen Lebensdauer  $L_0$ . Ein Betrieb des Bauteils unterhalb der spezifizierten Werte wirkt sich positiv auf die Lebensdauer aus. Der temperaturabhängige Anteil  $K_T$  basiert auf der Arrhenius-Gleichung. Diese besagt, dass bei einer Erhöhung der Betriebstemperatur  $T$  von  $n$  Grad sich die Lebensdauer des Bauteils halbiert. Dieser Effekt ist auf die schneller ablaufenden chemischen und physikalischen Effekte bei höheren Temperaturen zurückzuführen. Somit zersetzt sich der Elektrolyt bei höheren Temperaturen schneller oder diffundiert aus der Dichtung des Bauteils. Das führt dazu, dass der Anteil an leitfähigem Elektrolyten während der Alterung abnimmt und demnach der ESR steigt. I.d.R. wird unterhalb von 105 °C eine 10-Kelvin-Regel angegeben, wohingegen bei einem Betrieb oberhalb dieser Temperatur die Hersteller auf eine persönliche Kontaktaufnahme verweisen. Ergänzend sei erwähnt, dass die 10-Kelvin-Regel auch aufgrund der Qualität des Elektrolyten abweichen kann [10]. Der ripplestromabhängige Anteil  $K_R$  wird ebenfalls durch eine Arrhenius-Gleichung beschrieben. In diesem Fall erzeugt die Verlustleistung  $P_V$  über dem ESR nach Gleichung (2) eine Eigenerwärmung des Bauteils, was wiederum zu den in  $K_T$  beschriebenen Effekten führt.

$$P_V = \text{ESR} \cdot I_{\text{rms}}^2 \quad (2)$$

Zudem beschleunigen hohe Temperaturen die Entstehung von Fehlstellen in der Oxidschicht des Kondensators. Wohingegen bei Folienkondensatoren diese Fehlstellen weggebrannt werden und die effektive Kondensatorfläche reduziert wird, besitzt der Elektrolytkondensator einen Selbstheilungseffekt. Dieser ermöglicht es, die Fehlstellen zu regenerieren. Hierfür bildet sich beim Anlegen einer Spannung eine ausgeheilte Oxidschicht in den Fehlstellen [14]. Das notwendige Aluminium stellt die Anodenfolie bereit, während der Sauerstoff aus dem Elektrolyten entnommen wird. Je höher die angelegte Spannung ist, desto dicker wird die regenerierte Oxidschicht. Allerdings steigt auch in diesem Fall der ESR, da der verwendete Sauerstoff nicht mehr zur Ionenleitfähigkeit beiträgt. Demnach gilt, je größer die angelegte Spannung, desto mehr Sauerstoff wird dem Elektrolyten entnommen. Dieser Alterungseffekt wird durch den spannungsabhängigen Anteil  $K_U$  beschrieben. Zusätzliche Parameter wie  $K_i$  und  $n$  sind abhängig von der Bauform des Kondensators. So gilt beispielsweise, dass bei dünnen radialen

Bauformen das Verhältnis des Elektrolytreservoir zum Gesamtdurchmesser des Bauteils relativ groß ist, sodass  $n = 0$  gilt und demnach der spannungsabhängige Anteil vernachlässigt werden kann [9].

### 3. Konzept zur Zuverlässigkeitssimulation der Elektrolytkondensatoren

Da das Kältemittel R744 ( $\text{CO}_2$ ) sowohl zur Kühlung als auch im Wärmepumpenbetrieb verwendet werden kann, ist der Einsatz des elektrischen Kältemittelverdichters sowohl für warme als auch für kalte Regionen möglich. Demnach ergeben sich eine Vielzahl von Einsatzgebieten mit unterschiedlichsten Beanspruchungen der Komponente. Um die Zuverlässigkeit bereits während des Entwicklungsprozesses abschätzen zu können, werden mithilfe einer Multi-Domänen-Simulation die 15 Jahre Fahrzeuglebensdauer in verschiedenen klimatischen Zonen der Erde virtuell nachgebildet. Der Ablauf dieser Simulation ist in Abbildung 4 dargestellt.

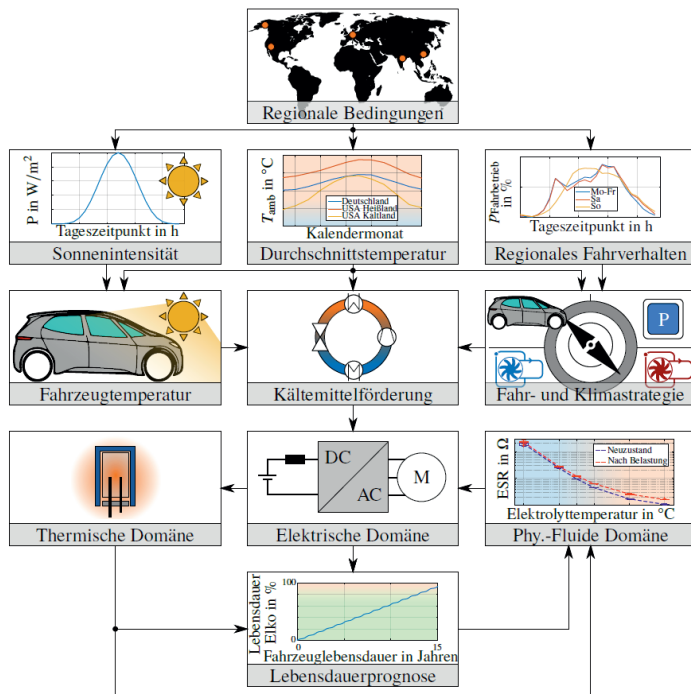


Bild 4: Konzept der Zuverlässigkeitssimulation.

Für die Simulation werden die Hauptabsatzmärkte China, Indien, Europa und USA betrachtet, wobei im Rahmen dieser Veröffentlichung lediglich ein Heißlandbeispiel USA (Yuma in Arizona) und ein Beispiel der gemäßigten Zone mit Deutschland (München in Bayern) herangezogen werden. Diese beiden Städte weisen unterschiedliche klimatische Verhältnisse auf und demnach auch unterschiedliche Verwendungen und Belastungen der Klimaanlage. Während in Yuma auch im Winter durchschnittliche zweistellige positive Temperaturen herrschen und im Sommer Temperaturen von über 40 °C nicht ungewöhnlich sind, hat München ein gemäßigtes Klima, sodass im Winter der Verdichter auch als Wärmepumpe betrieben wird. Auch die durchschnittlichen Fahrleistungen aus Tabelle 1 weisen Unterschiede der jeweiligen Länder vor. Dabei ist überwiegend die maximale Fahrdauern relevant, welche in Deutschland mit 71,3 Minuten und in den USA mit 75,6 Minuten angegeben wird. Demnach soll die Zuverlässigkeit der Kondensatoren auch bei Vielfahrern gewährleistet sein.

Tabelle 1: Fahrleistungen für Deutschland [15] und USA [16].

Absatzmarkt	Deutschland			USA		
Fahrleistung	Ø Min	Ø	Ø Max	Ø Min	Ø	Ø Max
Fahrstrecke pro Tag [km]	28	40,27	82,19	47	58,76	78,25
Fahrten pro Tag [-]	2	2,1	3,48	3	3,5	4,2
Fahrdauer pro Tag [min]	41	45	71,3	61,5	71,75	75,6

Zusätzlich kann der Kunde die Vorklimatisierung im Stillstand vor dem eigentlichen Fahrbetrieb aktivieren. Hierdurch summiert sich zur Fahrdauer bei hohen Umgebungstemperaturen bis zu 30 Minuten Air-Conditioning Betrieb (AC) und bei tiefen Umgebungstemperaturen bis zu 15 Minuten Wärmepumpen-Betrieb (WP) auf die Betriebszeit des Verdichters pro Fahrt.

Deshalb wird innerhalb der Multi-Domänen-Simulation zwischen den vier Klima- und Fahrstrategien Parken, Fahren, AC- und WP-Vorklimatisierung unterschieden. In Abhängigkeit der Umgebungsbedingungen und des Kundenwunschs zur Temperierung müssen unterschiedliche Kältemittelförderungen realisiert werden. Die verschiedenen Arbeitspunkte verursachen Rippelströme an den Elektrolytkondensatoren. Je nach Drehzahl des Verdichters und Hochdruck des Kältemittel im Kreislauf sind die Ströme über die Kondensatoren unterschiedlich. Im AC-Betrieb gilt, je höher die Umgebungstemperatur ist, desto stärker muss der Kompressor das Kältemittel verdichten, desto höher sind die Rippelströme über dem Zwischenkreis. Diese Rippelströme werden innerhalb der elektrischen Domäne auf die Kondensatortopologie bestehend aus drei parallelen Kondensatorsträngen mit jeweils zwei Kapazitäten verteilt. Durch pa-



parasitäre Induktivitäten wird der Kondensatorstrang, welcher sich am nächsten an den Leistungsschaltern befindet, am stärksten belastet. Diese asymmetrische Belastung der Kondensatortopologie sorgt innerhalb der thermischen Domäne zu unterschiedlichen Verlustleistungen und folglich individuellen Erwärmungen der Kondensatorstränge. Anhand der resultierenden Kerntemperatur wird die verbrauchte Lebensdauer der Elektrolytkondensatoren ermittelt. Wobei an dieser Stelle ein eigenes Lebensdauermodell basierend auf statistischer Versuchsplanung (engl. Design of Experiment, kurz DoE) oder die in Gleichung (1) beschriebene Lebensdauerformel verwendet werden kann. Des Weiteren dient die resultierende Kerntemperatur als Eingang der physikalisch-fluiden Domäne. In Abhängigkeit von der Temperatur und dem Alterungszustand stellt sich die Viskosität und somit die Leitfähigkeit des Elektrolyten ein. Demnach nimmt die Verlustleistung entsprechend Gleichung (2) während des Betriebes durch die höhere Kerntemperaturen ab. Allerdings steigen die Verlustleistungen insgesamt über die 15 Jahre Fahrzeugslebensdauer durch das allmähliche Austrocknen der Kondensatoren wie in Abschnitt 2 beschrieben.

#### 4. Empirische Parametererfassung

Zur Parametrisierung des in Abbildung 4 vorgestellten Modells, werden Versuche zur empirischen Erfassung der elektrischen, thermischen und physikalisch-fluiden Domäne durchgeführt. Des Weiteren wird mittels DoE ein Lebensdauermodell erstellt, welches die Alterung des Elektrolytkondensators entsprechend der Belastungen abschätzen kann.

Die elektrische Domäne behandelt die Aufteilung der Rippleströme über das Kondensatornetzwerk. Dieses kann mit dem elektrischen Ersatzschaltbild aus Abbildung 5 beschrieben werden.




Bild 5: Elektrisches Ersatzschaltbild der Zwischenkreistopologie mit parasitären Induktivitäten. Die Kapazitäten besitzen zusätzliche ohmsche und induktive Anteile.

Dabei bestehen die High-Side-Kondensatoren  $C_{HS,i}$ , bzw. die Kondensatoren, welche an der positiven Hochvoltspannung anliegen, und die Low-Side-Kondensatoren  $C_{LS,i}$  jeweils aus einer Kapazität  $C_i$ , einem äquivalenten Serienwiderstand  $R_{ESR,i}$  und einer äquivalenten Serieninduktivität  $L_{ESL,i}$ .

Der Ripplestrom über die Kondensatoren nimmt einen nahezu rechteckförmigen Verlauf an, welcher sich ungleich auf die Kondensatorstränge aufteilt. Diese asymmetrische Belastung entsteht unter anderem durch die verschiedenen Leitungslängen der verbundenen Kondensatoren, welche auch als parasitäre Induktivitäten  $L_{p,i}$  bezeichnet werden. Die Impedanz von Kondensatorstrang 1, welcher am nächsten an der B6-Brücke liegt, ist durch den niedrigsten Wert gekennzeichnet. Diese Strangimpedanz  $|Z_1|$  ist in Gleichung (3) dargestellt unter der Annahme, dass alle Kondensatoren identisch sind.

$$|Z_1| = \omega \cdot (2L_{ESL} + L_{p,5}) + 2R_{ESR,HS1} + \frac{2}{\omega C}, \text{ mit } \omega = 2\pi f \text{ und } f = 32 \text{ kHz} \quad (3)$$

$$|Z_3| = \omega \cdot (2L_{ESL} + L_{p,1} + L_{p,2} + L_{p,3} + L_{p,6} + L_{p,7}) + 2R_{ESR,HS1} + \frac{2}{\omega C} \quad (4)$$

Bei Kondensatorstrang 2  $|Z_2|$  kommen zusätzliche parasitäre Induktivitäten wie  $L_{p,2}$ ,  $L_{p,4}$  und  $L_{p,7}$  hinzu, wobei die Leitungsinduktivität  $L_{p,5}$  entfällt. Analog kann auch die Strangimpedanz 3 ermittelt werden, welche sich wie in Gleichung (4) dargestellt zusammensetzt. Dementsprechend ergibt sich die Aufteilung des Ripplestroms nach Tabelle 2.

Tabelle 2: Aufteilung des Ripplestroms auf die drei Kondensatorstränge basierend auf den unterschiedlichen Strangimpedanzen.

Kondensatorstrang $i$	1	2	3
$ Z_i / Z_{\text{gesamt}} $ [%]	32	33	35
Ripplestromanteil [%]	35	33	32

Die Gleichungen der Strangimpedanzen werden in die Zuverlässigkeitssimulation implementiert, wobei für die Kapazität und den ESR die temperatur-, frequenz- und alterungsabhängigen Parameter  $C(T, f, t)$  und  $R_{ESR}(T, f, t)$  eingesetzt werden.

Die Temperaturabhängigkeiten der Parameter werden in der physikalisch-fluiden Domäne modelliert. Dieser Effekt ist hauptsächlich auf die in Abschnitt 2 beschriebene Viskosität des Elektrolyten zurückzuführen. Die daraus resultierenden Verläufe sind in Bild 6 für einen 22µF-Kondensator visualisiert. Hierfür werden die Impedanzspektren von mehreren Kondensatoren bei

verschiedenen Temperaturen gemessen. Die temperaturabhängigen Verläufe werden ebenfalls während der Alterungstests durchgeführt, sodass der Einfluss von Parameterdrifteffekten auch bei verschiedenen Temperaturen möglich ist. Somit kann das elektrische Verhalten des Bauteils basierend auf dem aktuellen Zustand des flüssigen Elektrolyten detailliert nachgebildet werden.




Bild 6: Temperaturabhängiger Verlauf des ESR und der Kapazität.

Die dritte physikalische Disziplin bildet die thermische Domäne. In dieser wird die Eigenerwärmung der Bauteile nach Gleichung (2) berechneten Verlustleistungen bestimmt. Die physikalisch-fluiden Domäne liefert den Innenwiderstand der Bauteile  $R_{\text{ESR}}(T, f, t)$  und die elektrischen Domäne den Ripplestrom  $I_{\text{rms},i}$  über die jeweiligen Stränge. Zur Ermittlung der Kerntemperatur wird ein Cauer-Netzwerk nach Abbildung 7 verwendet, welche durch Herstellerangaben und empirische Versuche ermittelt wird.

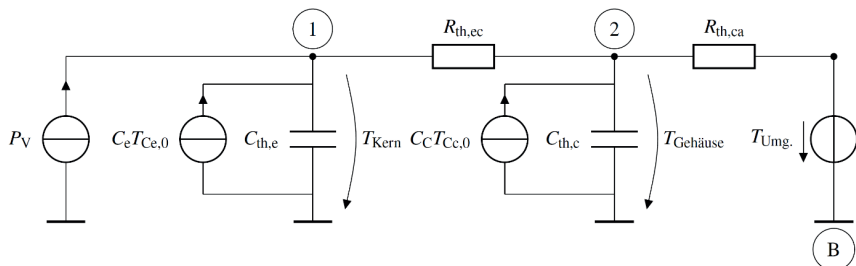


Bild 7: Cauer-Netzwerk eines Elektrolytkondensators zur Modellierung des thermischen Verhaltens des Bauteils.

Dabei sind die thermischen Kapazitäten des inneren Kondensatorwickелеlements  $C_{th,e}$  und den Aluminiumgehäuses  $C_{th,c}$ , sowie der Übergangswiderstand beider  $R_{th,ec}$  durch die baulichen Dimensionen des Elektrolytkondensators bestimmt. Der thermische Übergangswiderstand  $R_{th,ca}$  zur Umgebung kann jedoch durch ein Kühlkonzept wie Konvektion durch einen Lüfter oder Wärmeleitpaste reduziert werden. Durch die Messung der Gehäusetemperatur während der Eigenerwärmung des Bauteils kann auf den thermischen Übergangswiderstand  $R_{th,ca}$  geschlossen werden. Dieser wird vom Hersteller als 43 K/W angegeben. Allerdings gilt dieser Wert für den Betrieb bei ruhender Luft. Durch eine höhere Konvektion im Klimaschrank kann dieser auf unter 20 K/W reduziert werden. Die thermische Anbindung durch Wärmeleitpaste ermöglicht sogar eine Reduzierung auf unter 10 K/W. Durch die bessere thermische Anbindung, heizt sich das Bauteil nicht mehr so stark auf. Hierdurch wird zudem die Lebensdauer erhöht. Allerdings gilt dann nicht mehr der rippestromabhängige Anteil  $K_R$  aus Gleichung (1), da durch die Änderung der thermischen Kondensatoranbindung sich auch die rippestromabhängige Alterung ändert. Durch das Cauer-Netzwerk in Abb. 7 kann jedoch auf die Kerntemperatur geschlossen werden, wodurch der Anteil  $K_R$  entfallen und stattdessen die resultierende Kerntemperatur  $T_{Kern}$  in die Gleichung (1) für den temperatur-abhängigen Parameter  $K_T$  eingesetzt werden kann.

## 5. Darstellung der Ergebnisse und Diskussion

Die mittels Multi-Domänen-Simulation prädiizierte Alterung ist Bild 8 zu entnehmen. Für den Einsatzort Deutschland ergibt sich bei einer Fahrdauer von 71,3 Minuten pro Tag eine Alterung des vorderen Kondensatorstrangs um ca. 20 %. Diese Angabe gilt für das empirisch parametrisierte Modell und wird als „Standardwerte“ bezeichnet. Während die Vernachlässigung oder die Verdopplung der parasitären Induktivitäten lediglich eine Abweichung von  $\pm 1$  % ausmacht, hat die thermische Domäne einen höheren Stellenwert. Denn bei einer Annahme der Herstellerangaben zu dem thermischen Übergangswiderstand  $R_{th,ca}$  altert der Kondensatorstrang 1 um über 40 %. Dies entspricht einer stärkeren Alterung als bei einer Erhöhung der Fahrdauer auf zwei Stunden. Wenn zusätzlich die alterungsbedingten Parameterdrifteffekte und demnach erhöhten Verlustleistungen während der Fahrzeuglebensdauer hinzukommen, steigt die „verbrauchte“ Lebensdauer der Kondensatoren auf ca. 80 %. Da allerdings durch die Verwendung von Wärmeleitpaste die Kerntemperatur reduziert wird, ist die Alterung um 80 % kein realistisches Szenario.

Des Weiteren zeigt Abbildung 8b) die nach 15 Jahren ermittelte „verbrauchte“ Lebensdauer für verschiedene Einsatzregionen nach den Parametrisierungen aus Abschnitt 4. Dabei ist für die Vergleichbarkeit ebenfalls eine Fahrdauer von 71,3 Minuten pro Tag simuliert. Demnach

gilt, je höher die Umgebungstemperaturen, desto stärker altern die Kondensatoren, da der Kompressor das Kältemittelverdichten stärker verdichten muss und folglich zu höheren Rippleströmen und Eigenerwärmungen führen. Der Wärmepumpenbetrieb liefert lediglich in Deutschland einen geringen Anteil zur Alterung der Kondensatoren, da in wärmen Regionen dieser Modus in der Simulation nicht betrieben wird aufgrund der hohen Umgebungstemperaturen.

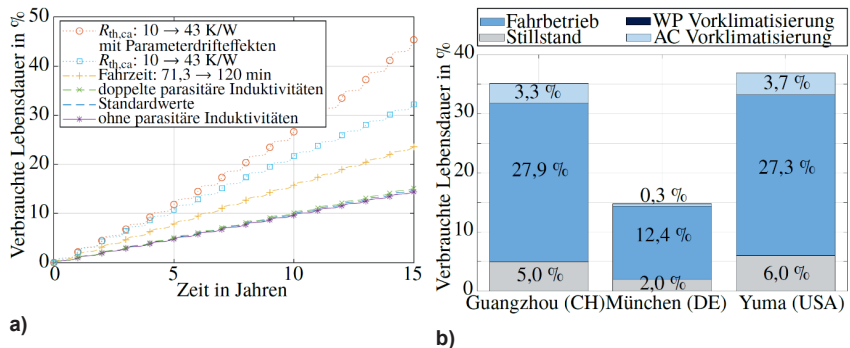


Bild 8: Darstellung der Alterung des Kondensatorstrangs 1. Abbildung a) zeigt den zeitlichen Verlauf der Alterung in Deutschland, während Abbildung b) die Alterung für verschiedene Regionen der Erde unterteilt in die vier Betriebsmodi visualisiert.

## 6. Zusammenfassung und Fazit

In dieser Arbeit wurde eine Methode zur Lebensdauerprädiktion von Elektrolytkondensatoren mittels Multi-Domänen-Simulation vorgestellt. Hierfür werden die Alterungseffekte der Kondensatoren, der Ablauf der Simulation und die Parametrisierung dieser vorgestellt. Die Darstellung der Ergebnisse zeigt, dass die Alterung der Bauteile stark von dem Einsatzort, der Parametrisierung und der angenommenen Belastungen der Komponente abhängig ist. In diesem Fall können die parasitären Induktivitäten des Kondensatornetzwerks vernachlässigt werden, da die Modellierung der thermischen Domäne einen deutlich größeren Einfluss besitzt. Die Simulation ermöglicht bereits während des Entwicklungsprozesses eine Lebensdauerabschätzung der Bauteile zu erhalten und Konzepte, wie z.B. den optimale Menge von Wärmeleitpaste, abzuschätzen. Gleichzeitig können Unter- oder Überdimensionierungen festgestellt und angepasst werden, was zur Sicherstellung der Zuverlässigkeit und zu einer Reduzierung des Kaufpreises für den Kunden führt.

- [1] DAT-Report 2002. Techn. Ber. (Stand: 29.12.2020). Deutsche Automobil Treuhand, 2002.
- [2] DAT-Report 2016. Techn. Ber. (Stand: 29.12.2020). Deutsche Automobil Treuhand, 2016.
- [3] DAT-Report 2018. Techn. Ber. (Stand: 29.12.2020). Deutsche Automobil Treuhand, 2018.
- [4] ZVEI Robustness Validation Working Group, Hrsg: Handbook for Robustness Validation of Automotive Electrical/Electronic Modules. Frankfurt am Main: ZVEI 2003
- [5] Ivers-Tiffée, E. und von Münch, W.. Werkstoffe der Elektrotechnik. Wiesbaden: Vieweg+Teubner Verlag 2007
- [6] Wang, H. und Blaabjerg, F.: Reliability of Capacitors for DC-Link Applications in Power Electronic Converters - An Overview. IEEE Transactions on Industry Applications 50.5 (2014), S. 3569–3578.
- [7] Wolfgang, E.: Reliability of Power Electronic Systems: An Industry Perspective. ECPE, Reliability of Power Electronic Systems Tutorial (2009)
- [8] Falck, J. et al.: Reliability of Power Electronic Systems: An Industry Perspective. IEEE Industrial Electronics Magazine 12 (2018) 2 S. 24-35
- [9] A, Albertsen. Electrolytic Capacitor Lifetime Estimation. Bodos Power Magazine. 52-54, 2010
- [10] K.H. Thiesbürger. Der Elektrolyt-Kondensator: Begriffe und Probleme. FRAKO Kondensatoren- u. Apparatebau, 1965.
- [11] Jianghai Europe, Hrsg. Technical Notes - Typical failure modes and factors of aluminum electrolytic capacitors. [https://jianghai-europe.com/wp-content/uploads/Failure\\_Modes.pdf](https://jianghai-europe.com/wp-content/uploads/Failure_Modes.pdf). (Stand: 19.12.2020).
- [12] Capacitors - Reliability - Typical Aluminum Electrolytic Capacitor Failure Modes and Their Causes, Technische Dokumentation, ELNA, Yokohama 2020
- [13] Aluminium Electrolytic Capacitors - Cautions for proper use of Aluminium Electrolytic Capacitor, Technische Dokumentation, Rubycon Corporation, Ina (Nagano) 2020
- [14] Ma, H. und Wang, L.: Fault diagnosis and failure prediction of aluminum electrolytic capacitors in power electronic converters. 31st Annual Conference of IEEE Industrial Electronics Society, 2005 S. 842–847.
- [15] Eisenmann, C. et al.: Analyse und Klassifizierung der Nutzung der Deutschen Pkw-Flotte zur Ermittlung von Verlagerungs- und Substitutionspotenzialen auf umweltverträgliche Verkehrsträger, Karlsruher Institut für Technologie (KIT) Abschlussbericht. Karlsruhe 2018
- [16] Federal Highway Administration: National Household Travel Survey. 2017 Summary Statistics for Demographic Characteristics and Travel, 2017.

# Messung des Alterungszustand von LEDs im verbauten Zustand über ihre elektrischen Größen und die Vorhersage der Zuverlässigkeit

M. Eng. **Benjamin Weigt, Kai Homeyer**,  
Industrieelektronik und Lichttechnik, Hochschule Hannover;  
Prof. Dr.-Ing. **Roland Lachmayer**,  
Fakultät für Maschinenbau, Institut für Produktentwicklung und  
Gerätebau, Leibniz Universität Hannover

## Kurzfassung

Der Alterungszustand von LEDs ist eine wichtige Fragestellung für Hersteller und Verbraucher gerade im Betrieb oder im verbauten Zustand, weil LEDs von der Innenraumbeleuchtung bis zum intelligenten Matrix-LED-Scheinwerfer zurzeit die wesentliche Lichtquelle in der Beleuchtungstechnik sind. Die Alterung und die Zuverlässigkeit von LEDs drücken sich über die Änderung der lichttechnischen Kenngrößen, Lichtstromdegradation und Farbortverschiebung, in Abhängigkeit der Alterungsbedingungen aus. Die Messung der lichttechnischen Größen ist allerdings im Betrieb gegenüber einer elektrischen Messung sehr aufwändig oder gar nicht möglich. Eine aktuelle Auswertung bestehender Messdaten eines Dauerversuches (10000 h) zeigt das Alterungsverhalten von LEDs anhand ihrer elektrischen Größen, Spannung und Strom, die im direkten Bezug zu den lichttechnischen Größen stehen und ermöglicht eine Vorhersage der Zuverlässigkeit aus dem aktuellen Alterungszustand.

## 1. Einleitung

LEDs sind zurzeit die wichtigste Lichtquelle in der Beleuchtungstechnik, weil sie universell mit ihrem ganzen Leistungsspektrum vom Human Centric Lighting (HCL) bis zum intelligenten Matrix-LED-Scheinwerfer eingesetzt werden. Der Lichtstrom und der Farbort sind wichtige Kenngrößen für LEDs, die sich während des Betriebes von Anfang an durch die Wirkung verschiedener Alterungsmechanismen wie z.B. Generation von Halbleiterdefekten [1, 2], Diffusion der Dotierungsstoffe [3, 4] oder Rissbildung im LED-Chip [3, 4] ändern. Die Wirkung der einzelnen Alterungsmechanismen hat einen großen Einfluss auf das gesamte Alterungsverhalten und die resultierende Zuverlässigkeit von LEDs. Der Alterungszustand ist dabei eine Momentaufnahme vom Alterungsverhalten, welches sich durch Lichtstromdegradation und Farbortverschiebung ausdrückt. Die Messung dieser lichttechnischen Größen ist gerade im eingebauten Zustand und im normalen Betrieb der einzelnen LED gegenüber einer elektrischen Messung sehr aufwändig oder gar nicht möglich wie z.B. die Messung des Lichtstromes von einer bestimmten LED im intelligenten Matrix-LED-Scheinwerfer. Hingegen ist die Änderung der *UI*-Kennlinie von LEDs während der Alterung gegenüber den lichttechnischen Größen einfacher und präziser

messbar und lässt außerdem Rückschlüsse auf die verschiedenen Alterungserscheinungen zu wie z.B. die Änderung der Rekombinationsraten [4], die Änderung der Beweglichkeit der Ladungsträger [4], die Senkung des Photostromes [9], die Erhöhung des Bahnwiderstandes [10], die Erhöhung des Vorwärts-Leckstromes [6 bis 8], die Erhöhung des parasitären Reihenwiderstandes [4, 6], und die Verschiebung der *UI*-Kennlinie im Rekombinationsbereich [6 bis 9]. Die Alterungserscheinungen entstehen durch die Wirkung verschiedener Alterungsmechanismen. Die Messdaten aus zwei Dauerversuchen mit über 10000 Betriebsstunden [13] zeigen die genannten Alterungserscheinungen in der *UI*-Kennlinie. Untersucht wurden High- und Mid-Power LEDs von verschiedenen gängigen Herstellern, die jeweils bei verschiedenen Betriebsströmen (350 mA, 700 mA und 1000 mA) und Umgebungstemperaturen (55 °C, 85 °C und 95 °C) gealtert sind. Die *UI*-Kennlinie von LEDs hat drei verschiedene charakteristische Bereiche in Durchlassrichtung (Abbildung 1, Rekombinations- (I), Diffusions- (II) und Hochstrombereich (III)), in denen sich die Steigung und der jeweilige Sättigungsstrom ändern. In diesen Bereichen sind Wirkungen unterschiedlicher Alterungsmechanismen von LEDs messbar. Diese Arbeit untersucht diese Bereiche der Kennlinie genauer, um eine Vorhersage der Zuverlässigkeit für die lichttechnischen Größen zu ermöglichen. Aus der Betrachtung ergeben sich die folgenden Fragestellungen:

1. Wie verändert sich allgemein die *UI*-Kennlinie von LEDs während der Alterung und welchen Einfluss haben dabei die Randbedingungen (Betriebsstrom und Umgebungstemperatur) auf die Änderungen?(Kapitel 2)
2. Welche Näherungsfunktion beschreibt die Änderung der *UI*-Kennlinie bei Alterung der LEDs mit Hilfe der interpolierten Messdaten? (Kapitel 3, 4, und 5)
3. Wie korrelieren die Änderungen der lichttechnischen Größen mit denen der *UI*-Kennlinie im Verlauf der Alterung der LEDs? (Kapitel 6)

Das Ziel dieser Arbeit ist die Erstellung eines Modells, um den Alterungszustand von LEDs im Betrieb zu erfassen, die Zuverlässigkeit vorherzusagen und damit Informationen an die Steuerung der LEDs zur möglichen Korrektur des Betriebspunktes oder vorrausschauende Diagnosedaten zur Wartung zu liefern.

## 2. Veränderung der *UI*-Kennlinie von LEDs aufgrund ihrer Alterung

Der exponentielle Verlauf der *UI*-Kennlinie teilt sich in die zwei Hauptbereiche Durchlass- (1. Quadrant) und Sperrbereich (3. Quadrant) auf [11]. Der Durchlassbereich lässt sich in die drei weiteren Bereiche Rekombinations- (I), Diffusions- (II) und Hochstrombereich (III) unterteilen (Abbildung 1), in denen sich jeweils die Steigung und der jeweilige Sättigungsstrom durch den vorherrschenden Stromleitungseffekt unterscheiden [11, 12]. Im Rekombinationsbereich (I) ist der Verlauf abhängig vom Nettorekombinationsstrom, der von der Gesamtbilanz zwischen Rekombinations- und Generationsrate abhängt. Außerdem wirkt in diesem Bereich die Sperr-



schicht, sodass die Ströme der beweglichen Ladungen (Löcher und Elektronen) noch sehr klein sind. Im Diffusionsbereich (II) ist die Sperrschicht, welche durch die Diffusion der Minoritätsträger im Halbleitermaterial entsteht, durch das Überschreiten der Diffusionsspannung (weiße LED  $U_D$  ca. 2,6 V) abgebaut, wodurch der Anteil des Löcher- und Elektronenstroms ansteigt. Im Hochstrombereich (III) sind der Löcher- und Elektronenstrom viel größer als der Nettorekombinationsstrom und diese bestimmen maßgeblich den Verlauf. Hier liegt normalerweise der Betriebspunkt von LEDs, weil sie ab dem Überschreiten der Diffusionsspannung Licht emittieren. Im Sperrbereich einer kommerziellen LED wirkt typischerweise das parallel angeschlossene Schutzelement. Weil keine Informationen vom Hersteller über das interne Schutzelement der LED vorhanden sind, wird der Sperrbereich in dieser Arbeit nicht weiter untersucht.




Abbildung 1: Alterungsverhalten der  $UI$ -Kennlinien einer exemplarischen weißen LED im Rekombinations- (I), Diffusions- (II) und Hochstrombereich (III), Strom in Durchlassrichtung logarithmisch skaliert (eigene Messung)

Auf die drei Bereiche der  $UI$ -Kennlinie wirken verschiedene Alterungsmechanismen, die über die Messung der Diodenspannung bei vorgegebenem Messstrom identifizierbar sind. Im Hochstrombereich ist eine Verschiebung in Richtung höherer Diodenspannung bei konstantem Diodenstrom aufgrund der Erhöhung des Bahnwiderstandes im Halbleitermaterial erkennbar (Abbildung 1). Die Stärke der Erhöhung des Bahnwiderstandes ist abhängig von den Randbedingungen (Strom, Umgebungstemperatur) im Betrieb. Die Diodenspannung im Diffusionsbereich und somit auch die Diffusionsspannung verschieben sich während der Alterung aufgrund der Änderung der Donator- und Akzeptorkonzentration bzw. des Dotierungsprofils (vgl. Abbildung 2). Dieses Verhalten wird durch eine thermische Überlastung der LED hervorgerufen. Die

Änderung im Diffusionsbereich (II) ist gegenüber der Änderung im Rekombinations- (I) und Hochstrombereich (III) deutlich kleiner. Der Rekombinationsbereich (I) verschiebt sich durch die Änderung der Gesamtbilanz zwischen Rekombinations- und Generationsrate (Abbildung 1,  $I_{\text{mess}} = 100 \text{ nA}$ ), da sich die strahlende und die nicht-strahlende Rekombination während der Alterung ändern.

Wesentliche Gründe für die Änderung in den Kennlinienbereichen zusammengefasst:

Rekombinationsbereich (I) → Rekombinationsraten

Diffusionsbereich (II) → Dotierungsprofil oder Dotierungskonzentration

Hochstrombereich (III) → Bahnwiderstand (Beweglichkeit der Ladungsträger)

Die Entwicklung eines Modells erfordert eine genauere Betrachtung der Diodenspannungen in den drei Bereichen über die Betriebszeit. Dafür sind beispielhaft die Diodenspannungen mit dem Messstrom als Parameter für zwei LEDs mit verschiedenen Alterungsverhalten bei gleichen Randbedingungen (Betriebsstrom  $I = 1000 \text{ mA}$  und Umgebungstemperatur  $T = 95 \text{ °C}$ ) während einer Alterungsdauer von 0 bis 11516 Betriebsstunden gegenübergestellt (Abbildung 2).




Abbildung 2: Änderung der Diodenspannung bei verschiedenen Messströmen (100 nA, 10 µA, 1 A) von zwei LEDs, gealtert bei den gleichen Randbedingungen (1000 mA / 95 °C) (eigene Messung)

Der Verlauf der Diodenspannung ist bis 5000 h bei beiden LEDs identisch und zeigt die beschriebenen Alterungserscheinungen (Abbildung 2). Ab diesem Zeitpunkt hat die „sehr stark“ gealterte LED (blaue Kurven) ein besonderes Alterungsverhalten. Die Diodenspannung im Hochstrombereich steigt stärker an. Daraus resultiert eine erhöhte Verlustleistung, die in diesem Fall zur thermischen Überlastung der LED führt. Aufgrund der thermischen Überlastung

(Abbildung 2, blaue Kurve 100 nA nach 7750 h) verschieben sich auch der Rekombinations- ( $I_{\text{mess}} = 100 \text{ nA}$ ) und Diffusionsbereich ( $I_{\text{mess}} = 10 \mu\text{A}$ ) stärker. Eine Folge von der Erhöhung im Diffusionsbereich ist der Anstieg der Diffusionsspannung. Dieses Verhalten wird an dieser Stelle nicht weiter betrachtet, weil für die Untersuchung eine komplexe kapazitive Messung der LED nötig ist. Der Lichtstrom der zweiten LED degradiert stärker auf unter 50 % des Anfangswertes. Die unterschiedlichen Verläufe entstehen durch die Wirkung verschiedener Alterungsmechanismen wie der Entstehung von tiefen Störstellen, der Änderung des Dotierungsprofils und der Dotierungskonzentration, der Rissbildung im LED-Chip, der metallurgischen Interdiffusion der elektrischen Kontakte sowie der Generation von Halbleiterdefekten [1 bis 4]. Die Randbedingungen beeinflussen die Geschwindigkeit und Stärke der Alterungsmechanismen (vgl. das Gesetz der Aktivierungsenergie nach Arrhenius) [4, 14].

Die Diodenspannung im Rekombinationsbereich steht aufgrund der Erhöhung von Leckströmen während der Alterung im direkten Zusammenhang mit der resultierenden Lichtstromdegradation [1, 16]. Zur weiteren Übersicht des Alterungsverhaltens der Diodenspannung im Rekombinationsbereich zeigen die Messdaten beispielhaft in Abbildung 3 den Einfluss der Randbedingungen durch eine konstante Umgebungstemperatur von 95 °C bei drei verschiedenen Betriebsströmen (350 mA, 700 mA, 1000 mA). Die Änderung der Diodenspannung im Rekombinationsbereich ist bei einem Messstrom  $I_{\text{mess}} = 100 \text{ nA}$  gemessen. Es ist jeweils der Verlauf als Mittelwert der Messwerte von 20 gleichen und unter gleichen Randbedingungen gealterten LEDs samt deren Standardabweichung dargestellt.

Die Verschiebung der Diodenspannung während der Alterung ist maßgeblich von den Randbedingungen, Umgebungstemperatur und Betriebsstrom, im Betrieb abhängig. Einerseits gilt je höher der Betriebsstrom und die Umgebungstemperatur desto größer ist die Verschiebung der Diodenspannung im Rekombinationsbereich (Abbildung 3). Dieses Verhalten korreliert mit der Lichtstromdegradation. Andererseits steigt bei einem geringeren Betriebsstrom (350 mA) die Diodenspannung an und bleibt konstant. Dieses Verhalten korreliert nicht der Lichtstromdegradation. Aus diesem Grund erfordert die Modellierung eine Einteilung der Randbedingungen, um das jeweilige Alterungsverhalten von LEDs präzise mit einer Näherungsfunktion abzubilden und eine verbesserte Vorhersage der Zuverlässigkeit zu ermöglichen. Die Näherungsfunktion für die Interpolation der Diodenspannung im Rekombinationsbereich muss je nach „Härte“ der Randbedingung angepasst werden. Eine generelle Einteilung erfolgt in zwei Arten der Randbedingungen: Erstens die „kritischen“ Randbedingungen bei einer sinkenden Diodenspannung und zweitens die „unkritischen“ Randbedingungen für eine steigende Diodenspannung. Die Einteilung der Randbedingungen erfolgt nach der Analyse aller elektrischen und optischen Messdaten (Tabelle 1). Die gewählte Näherungsfunktion ist eine Exponentialfunktion für die „kritischen“ Randbedingungen und ihre zugehörige Umkehrfunktion (Logarithmusfunktion)

für die „unkritischen“ Randbedingungen (Tabelle 1), weil die Extrapolation der Lichtstromdegradation nach IES TM 21-11 [15] und das Gesetz der Aktivierungsenergie nach Arrhenius [4, 14] eine Exponentialfunktion verwenden.




Abbildung 3: Änderung der Diodenspannung im Rekombinationsbereich gemessen bei  $I_m = 100 \text{ nA}$  bei konstanter Umgebungstemperatur (95 °C) und bei drei verschiedene Betriebsströme (350 mA, 700 mA, 1000 mA) [13]

Tabelle 1: Auflistung der für die Alterung „kritischen“ und „unkritischen“ Randbedingungen für die Auswertung der Messdaten mit Hilfe der jeweiligen Näherungsfunktion

Nr.	Konstante Randbedingung	Variable Randbedingung	Art der Randbedingung	Näherungsfunktion
1	$T = 95 \text{ °C}$	$I = 350 \text{ mA}, 700 \text{ mA}, 1000 \text{ mA}$	Kritisch	e
2	$I = 1000 \text{ mA}$	$T = 55 \text{ °C}, 85 \text{ °C}, 95 \text{ °C}$	Kritisch	e
3	$I = 700 \text{ mA}$	$T = 55 \text{ °C}, 85 \text{ °C}, 95 \text{ °C}$	Kritisch	e
4	$T = 55 \text{ °C}$	$I = 350 \text{ mA}, 700 \text{ mA}, 1000 \text{ mA}$	Unkritisch	ln
5	$I = 350 \text{ mA}$	$T = 55 \text{ °C}, 85 \text{ °C}, 95 \text{ °C}$	Unkritisch	ln

3. Interpolation der Diodenspannung im Rekombinationsbereich mit einer Exponentialfunktion für „kritische“ Randbedingungen

Die Diodenspannung von LEDs im Rekombinationsbereich ändert sich während ihres Betriebes in Abhängigkeit der Randbedingungen, Umgebungstemperatur und Betriebsstrom (Kapitel 2). In diesem Kapitel ist dieses Verhalten der Diodenspannung durch die Interpolation der Messdaten unter Verwendung einer Exponentialfunktion beschrieben (Formel 2). Die Koeffizienten  $\alpha$  und der

Startwert  $u_{\text{start}}$  modellieren dabei die „kritischen“ Randbedingungen (vgl. Tabelle 1) und sind mit dem Gütemaß  $R^2$  bewertet.




Abbildung 4: Gütemaß ( $R^2$ ) in Abhängigkeit des Koeffizienten ( $\alpha$ ) bei konstanter Umgebungstemperatur (95 °C) während der Alterung bei drei verschiedenen Betriebsströmen (350 mA, 700 mA, 1000 mA)

Abbildung 4 stellt beispielhaft das Gütemaß  $R^2$  der Exponentialfunktion in Abhängigkeit des Koeffizienten  $\alpha$  für die Randbedingungen, konstante Umgebungstemperatur 95 °C und drei Betriebsströme (350 mA, 700 mA, 1000 mA), dar, um eine Übersicht über das gesamte Alterungsverhalten der untersuchten LEDs zu erhalten. Die Auswertung in Abbildung 4 verdeutlicht bei den Koeffizienten eine klare Trennbarkeit für die verschiedenen Randbedingungen (Höhe des Betriebsstromes bei konstanter Umgebungstemperatur). Die Streuungen der Koeffizienten bei den Randbedingungen 350 mA und 700 mA sind geringer gegenüber der Randbedingung 1000 mA, allerdings ist das Gütemaß bei den Randbedingungen 1000 mA und 700 mA deutlich höher. Bei der Auswertung der gesamten Messdaten von allen Randbedingungen ergeben sich die folgenden Hauptaussagen für die Koeffizienten und Gütemaße:

1. Gute Trennbarkeit der Koeffizienten bei verschiedenen Randbedingungen
2. Gutes Gütemaß bei „kritischen“ Randbedingungen
3. Größerer Betrag des Koeffizienten bei „kritischen“ Randbedingungen
4. Positive Koeffizienten bei „unkritischen“ Randbedingungen
5. Schlechtes Gütemaß bei „unkritischen“ Randbedingungen

Die verschiedenen Koeffizienten  $\alpha$  bei „kritischen“ Randbedingungen sind in vier Gruppen eingeteilt (Tabelle 2).

Tabelle 2: Gruppierung der Koeffizienten und das Gütemaß der Exponentialfunktion

Koeffizient $\alpha$	Gütemaß $R^2$
$< -3 \cdot 10^{-5}$	$> 0,95$
$-4 \cdot 10^{-6}$ bis $-3 \cdot 10^{-5}$	$0,6 - 0,95$
$0$ bis $-4 \cdot 10^{-6}$	$< 0,6$
$0$ bis $1 \cdot 10^{-5}$	$0,1 - 0,6$

#### 4. Interpolation der Diodenspannung im Rekombinationsbereich mit einer Logarithmusfunktion für „unkritische“ Randbedingungen

Die Exponentialfunktion als Näherungsfunktion hat bei den „unkritischen“ Randbedingungen, Umgebungstemperatur und Betriebsstrom, ein schlechtes Gütemaß  $R^2$ , weil die Diodenspannung bei den „unkritischen“ Randbedingungen (vgl. Tabelle 1) ansteigt und konstant bleibt (Abbildung 3, 350 mA). Für die Verbesserung des Gütemaßes wird die zugehörige Umkehrfunktion (Logarithmusfunktion) mit einem Startwert  $u_{\text{start}}$  als Näherungsfunktion verwendet (Formel 3).

$$u(t) = \beta \cdot \ln(t) + u_{\text{start}} \quad (3)$$

Die Auswertung der Messdaten für „unkritische Randbedingungen“ zeigt in Abbildung 5 das Gütemaß der Logarithmusfunktion in Abhängigkeit des Koeffizienten  $\beta$  beispielhaft für die Randbedingungen bei einer konstanten Umgebungstemperatur von  $T = 55^\circ\text{C}$  und drei verschiedenen Betriebsströmen (350 mA, 700 mA, 1000 mA). Das Gütemaß steigt allerdings nur bei den niedrigsten Randbedingungen (350 mA,  $55^\circ\text{C}$ ). Dadurch können folgende Hauptaussagen formuliert werden:

1. Das Gütemaß  $R^2$  steigt durch die Verwendung der Logarithmusfunktion bei „unkritischen“ Randbedingungen.
2. Der Koeffizient  $\beta$  ist immer positiv bei „unkritischen“ Randbedingungen, dadurch ist eine gute Trennbarkeit zwischen „kritischen“ und „unkritischen“ Randbedingungen möglich.
3. Schlechtes Gütemaß  $R^2$  bei „kritischen“ Randbedingungen

Die Koeffizienten der Randbedingungen einer unkritischen Belastung sind in zwei Gruppen eingeteilt (Tabelle 3).

Tabelle 3: Gruppierung der Koeffizienten und das Gütemaß der Logarithmusfunktion

Koeffizient $\beta$	Gütemaß $R^2$
$0,004$ bis $0,01$	$0,68 - 0,85$ (Ausreißer $0,4$ )
$-0,025$ bis $0,004$	$0,15 - 0,4$




Abbildung 5: Gütemaß in Abhängigkeit des Koeffizienten bei konstanter Umgebungstemperatur (55°C) und drei verschiedenen Betriebsströmen (350 mA, 700 mA, 1000 mA)

## 5. Kategorisierung des Alterungsverhaltens als Grad der Alterung

Die verwendeten Näherungsfunktionen haben in Abhängigkeit der verschiedenen Randbedingungen der Alterung ein schlechtes bis sehr gutes Gütemaß und deutlich trennbare Koeffizienten. Demnach ist für die Modellierung je nach Randbedingung die Verwendung der jeweiligen Näherungsfunktion und eine weitere Kategorisierung wichtig. Dafür sind in Tabelle 4 die Koeffizienten ( $\alpha$  oder  $\beta$ ) und das Gütemaß ( $R^2$ ) der Exponentialfunktion (Kapitel 4) sowie der Logarithmusfunktion (Kapitel 5) für die verschiedenen Randbedingungen von einer „schwachen“ bis „sehr starken“ Alterung kategorisiert.

Tabelle 4: Kategorisierung des Alterungsverhaltens der untersuchten LEDs in Abhängigkeit der Randbedingungen

Kategorie	Grad der Alterung	Randbedingung	Näherungsfunktion	Koeffizienten $\alpha / \beta$	Gütemaß
1	„Schwach“	350 mA und 55°C, 85°C oder 95°C	ln	0,004 bis 0,01	0,68 bis 0,85 (0,4 Ausreißer)
2	„Normal“	55°C und 700 mA oder 1000 mA	e	0 bis $-4 \cdot 10^{-6}$	<0,6
3	„Stark“	700 mA und 85°C oder 95°C	e	$-4 \cdot 10^{-6}$ bis $-3 \cdot 10^{-5}$	0,6-0,95
4	„Sehr stark“	1000 mA und 85°C oder 95°C	e	Ab $-3 \cdot 10^{-5}$	>0,95

Die Einteilung in Kategorien hilft bei der Modellierung durch eine Korrelation zwischen der Diodespannung und dem Lichtstrom. Im folgenden Kapitel 6 ist die Korrelation für die Kategorien einer „schwachen“ und einer „sehr starken“ Alterung beschrieben, um einen Überblick über den gesamten Zusammenhang zwischen Lichtstromdegradation und der Verschiebung der Dioden-

spannung in Abhängigkeit der verschiedenen Randbedingungen herzustellen. Die Korrelation ermöglicht dem Anwender das gesuchte optische Alterungsverhalten von LEDs im Betrieb über die Messung der Diodenspannung im Rekombinationsbereich zu beobachten.

## **6. Korrelation zwischen Lichtstromdegradation und Verschiebung der Diodenspannung im Rekombinationsbereich**

Die lichttechnische Größe Lichtstrom ist für den Anwender von LEDs die wichtigste und interessanteste Kenngröße, die sich während der Alterung ändert. Im direkten Zusammenhang mit der Lichtstromdegradation steht die Erhöhung von Leckströmen während der Alterung und die daraus resultierende Änderung der Diodenspannung im Rekombinationsbereich [1, 16]. Daher ist in diesem Kapitel der Zusammenhang zwischen der Verschiebung der Diodenspannung im Rekombinationsbereich und der Lichtstromdegradation für die verschiedenen Randbedingungen (schwache, normale, starke und sehr starke Belastung) statistisch untersucht, um das Alterungsverhalten des Lichtstromes über die Diodenspannung zu beobachten. Die Auswertungen in Abbildung 6 und Abbildung 7 zeigen beispielhaft die Korrelation für eine „schwache“ und eine „sehr starke“ Alterung, um den gesamten Bereich der Kategorien vom Grad der Alterung (Tabelle 4) abzubilden. Bei einer „schwachen“ Alterung (Abbildung 6) mit den Randbedingungen 350 mA / 55 °C (Kreuze) und 350 mA / 95 °C (Sterne) steigt die Diodenspannung im Rekombinationsbereich auf einen bestimmten prozentualen Wert vom Anfangswert an. Um diesen Wert entsteht eine Punktwolke mit der Tendenz eines sinkenden Lichtstroms. In der Kategorie einer „schwachen“ Alterung wirken andere Alterungsmechanismen gegenüber einer „starken“ Alterung. Der Lichtstrom nimmt aufgrund der Leuchtstoffdegradation ab und nicht durch die Alterung des LED-Chips. Dieses Verhalten ist im zugehörigen Spektrum der LED durch die Abnahme des Strahlungsflusses im leuchtstoffkonvertierten Wellenlängenbereich zu beobachten. Der blaue Wellenlängenbereich bleibt hingegen annähernd konstant. In der Kategorie einer „schwachen“ Alterung ist eine Beobachtung des Lichtstromes über die Messung der Diodenspannung im Rekombinationsbereich nicht möglich. Hier sind zusätzliche Information über die Leuchtstoffdegradation erforderlich.

Die „sehr starke“ Alterung (Abbildung 7) hat eine sehr gute lineare Abhängigkeit mit einem sehr guten Gütemaß ( $R^2 > 0,9$ ) bei den Messdaten aller vier Versuchsgruppen (VG) vom gleichen LED-Typ zwischen der Lichtstromdegradation und der Verschiebung der Diodenspannung im Rekombinationsbereich. Das Spektrum der „sehr stark“ gealterten LED verschiebt sich im leuchtstoffkonvertierten wie auch im blauen Wellenlängenbereich. Hier überlagern sich die Alterung des LED-Chips und des Leuchtstoffes. In der Kategorie einer „sehr starken“ Alterung ist mit Hilfe der Korrelation zwischen Diodenspannung und Lichtstrom der Alterungszustand der LED über die gemessene Diodenspannung beobachtbar. Dadurch ist der Lichtstrom indirekt über die Diodenspannung messbar und ermöglicht mit Hilfe einer Extrapolation der Messdaten



(IES TM21-11) die Vorhersage der Zuverlässigkeit. Außerdem ist eine Korrektur des Lichtstromes durch eine Regelung des Betriebspunktes möglich.




Abbildung 6: Korrelation zwischen Lichtstromdegradation und Verschiebung der Diodenspannung im Rekombinationsbereich bei einer „schwachen“ Alterung (jeweils zwei Versuchsgruppen bei 350 mA / 55 °C und 350 mA / 95 °C)




Abbildung 7: Korrelation zwischen Lichtstromdegradation und Verschiebung der Diodenspannung im Rekombinationsbereich bei einer „sehr starken“ Alterung (vier Versuchsgruppen 1000 mA / 95 °C)

## 7. Zusammenfassung und Ausblick

Die  $UI$ -Kennlinie von LEDs verschiebt sich im Rekombinations- und im Hochstrombereich aufgrund verschiedener Alterungsmechanismen in Abhängigkeit der Randbedingungen der Alterung (Kapitel 2). Die Auswertung der elektrischen Messdaten bestätigt den Einfluss von Umgebungstemperatur und Betriebsstrom auf die Verschiebung der drei verschiedenen charakteristischen Bereiche der  $UI$ -Kennlinie (Abbildung 1). Die Arbeit untersucht hauptsächlich die Korrelation zwischen der Diodenspannung im Rekombinationsbereich und dem Lichtstrom, weil dieser aufgrund der Erhöhung von Leckströmen während der Alterung im direkten Zusammenhang mit der resultierenden Lichtstromdegradation steht [1, 16] und eine Änderung in Abhängigkeit der Randbedingungen aufweist. Eine schnellere Verschiebung der  $UI$ -Kennlinie im Rekombinationsbereich ist die Folge von höheren Belastungen während der Alterung. Dieses Verhalten korreliert mit der Lichtstromdegradation und stimmt mit dem physikalisch chemischen Gesetz der Aktivierungsenergie nach Arrhenius überein. Hingegen steigt bei geringeren Belastungen die Diodenspannung im Rekombinationsbereich an. Aus dem Grund des unterschiedlichen Verhaltens sind die verschiedenen Randbedingungen nach „Härte“ in „kritisch“ und „unkritisch“ eingeteilt, um die Messdaten der Diodenspannung mit einer Exponential- oder einer Logarithmusfunktion zu interpolieren (Kapitel 3 und 4). Die geeignete Näherungsfunktion ermöglicht eine Vorhersage der Diodenspannung im Verlauf der Alterung. Die Koeffizienten der Näherungsfunktion sind jeweils in Abhängigkeit der Randbedingungen deutlich voneinander trennbar (Abbildung 4 und Abbildung 5). Dadurch ist das Alterungsverhalten der getesteten LEDs weiter in die vier Kategorien „schwach“, „normal“, „stark“ und „sehr stark“ kategorisierbar, um seine Modellierung bei den verschiedenen Randbedingungen zu ermöglichen (Tabelle 4) und generell das Alterungsverhalten abzuschätzen. Die Korrelation zwischen Lichtstromdegradation und Änderung der Diodenspannung verdeutlicht für die verschiedenen Kategorien eine unterschiedliche Abhängigkeit (Kapitel 7). Einerseits sind die Verschiebung der Diodenspannung im Rekombinationsbereich und die Degradation des Lichtstroms in der Kategorie einer „starken“ und „sehr starken“ Alterung mit einem sehr guten Gütemaß  $R^2$  linear abhängig (Abbildung 7). Andererseits steigt bei einer „schwachen“ Alterung mit den Randbedingungen von 350 mA / 55 °C und 350 mA / 95 °C die Diodenspannung an, wodurch eine Punktwolke mit der Tendenz eines abnehmenden Lichtstroms bei der konstanten Diodenspannung entsteht (Abbildung 6). Die Korrelation ist unterschiedlich für jede Kategorie der Alterung. In der Kategorie einer „starken“ und „sehr starken“ Alterung ist der Lichtstrom über die Messung der Diodenspannung beobachtbar. In der Kategorie einer „schwachen“ Alterung ist die Beobachtung des Lichtstromes über die Diodenspannung nicht möglich. Der Unterschied des Alterungsverhaltens von „schwacher“ und „sehr starker“ Alterung entsteht durch die Wirkung verschiedener Alterungsmechanismen. Einerseits entsteht die „starke“ und „sehr starke“ Alterung hauptsächlich durch die Entstehung von Defek-

ten im LED-Chip. Die „schwache“ Alterung ist andererseits die Folge der Leuchtstoffdegradation, die anhand der elektrischen Größen nicht messbar ist. Eine Bestimmung der Kategorie bzw. dem Grad der Alterung ist nur bei einer altersbedingten Änderung der Diodenspannung möglich. Bei einer während des Betriebes von Anfang an konstant bleibenden Diodenspannung ist der Grad der Alterung „schwach“.

Der Alterungszustand von LEDs ist im Betrieb oder im eingebauten Zustand über die Diodenspannung im Rekombinationsbereich im Fall einer „starken“ und „sehr starken“ Alterung messbar, beobachtbar und daraus resultierend mit der zugehörigen Näherungsfunktion vorhersagbar. Die Änderung der Diodenspannung der LED muss überwacht werden, um die Kategorie der Alterung festzustellen. Die Korrelation zwischen Lichtstromdegradation und Änderung der Diodenspannung verdeutlicht für die verschiedenen Kategorien, dass der Lichtstrom durch eine einfache und präzise elektrische Messung der Diodenspannung für bestimmte Randbedingungen nachzubilden ist (Kapitel 7). Des Weiteren ist die Überwachung des Alterungszustandes einzelner LEDs im Betrieb oder im eingebauten Zustand möglich, um so eine Verschlechterung oder sogar einen Ausfall wichtiger Beleuchtungstechnik zu prognostizieren. Außerdem können zusätzliche Informationen an die Steuerung der LEDs weitergegeben werden, die den Lichtstrom durch die Änderung des Betriebspunktes korrigiert. Eine Extrapolation der Diodenspannung ermöglicht mit Hilfe der dazugehörigen Näherungsfunktion und Korrelation eine Vorhersage der Zuverlässigkeit, um z.B. den Zeitpunkt für die Unterschreitung einer Sicherheitsschwelle zu bestimmen.

## Quellen

- [1] La Grassa M., Meneghini M., De Santi C., Mandurrino M., Goano M., Bertazzi F., Zeisel R., Galler B., Meneghesso G., Zanoni E.: "Ageing of InGaN-based LEDs: Effects on internal quantum efficiency and role of defects", *Microelectronics Reliability*, 55, 9-10, 2015, 1775–1778
- [2] Meneghini, M.; Dal Lago, M.; Trivellin, N.; Meneghesso, G.; Zanoni, E.: "Degradation Mechanisms of High-Power LEDs for Lighting Applications", *IEEE Trans. on Ind. Applicat. (IEEE Transactions on Industry Applications)*, 50, 1, 2014, 78-85
- [3] Homeyer, K., Kopp, H., Ganev, H.: „Alterung von Hochleistungs-LEDs – Alterungsmechanismen und Ergebnisse“, 10. VDI-Fachtagung Innovative Beleuchtung mit LED, Düsseldorf, 8.-9.11.2012
- [4] Chang M.-H., Das D., Varde P.V. und Pecht M.: "Light emitting diodes reliability review", *Microelectronics Reliability*, 52, 5, 2012, 762-782
- [5] Vos T., den Breeijan P. und van Driel W. D.: "Quality and Reliability in Solid-State-Lighting: Qua Vadis?", In: *Solid State Lighting Reliability Part 2*. by Willem Dirk van Driel, Xuejun Fan and Guo Qi Zhang, Bd. 3, *Solid State Lighting Technology and Application Series*, Cham and s.l.: Springer International Publishing, ISBN: 978-3319581743, 2018, 1-14
- [6] Buffolo M., De Santi C., Meneghini M., Rigon D., Meneghesso G. and Zanoni E., "Long-term degradation mechanisms of mid-power LEDs for lighting applications", *Microelectronics Reliability* 55 (2015), 2015, 1754–1758
- [7] Lee S. W., Oh D. C., Goto H., Ha J. S., Lee H. J., Hanada T., Cho M. W., Yao T., Hong S. K., Lee H. Y., Cho S. R., Choi J. W., Choi J. H., Jang J. H., Shin J. E., and Lee J. S.: "Origin of forward leakage current in GaN-based light-emitting devices", *Appl. Phys. Lett.* 89,

- 132117, American Institute of Physics, 2006
- [8] Fang Z.-Q., Reynolds D. C., Look, D. C.: "Changes in electrical characteristics associated with degradation of InGaN blue light-emitting diodes", *Journal of Electronic Materials*, 29, 4, 2000, 448-451
  - [9] Weigt B., Homeyer K.: "Einfluss von Betriebsstrom und Umgebungstemperatur auf den Alterungszustand der elektrischen Größen von High Power LEDs", *Lux Junior* 2019, 10.22032/dbt.39601, 2019, 77-85
  - [10] Homeyer K.: „Alterungsuntersuchungen an Hochleistungs-LEDs: Verfahren, Beobachtungen, Messergebnisse“; LICHT 2014, 21. Gemeinschaftstagung, Den Haag, 21.9.–24.09.2014, Tagungsband / Deutsche Lichttechnische Gesellschaft e.V.; Lichttechnische Gesellschaft Österreichs; Schweizer Licht Gesellschaft; Nederlandse Stichting Voor Verlichtingskunde (NSVV) (Hrsg.), PPN: 797732705, 2014, 346-353
  - [11] U. Tietze, Ch. Schenk, "Halbleiter Schaltungstechnik", Springer, 12. Auflage, 3-540-42849-6, 2002, 16-19
  - [12] Awaah M. A., Nana R., Das K.: "Analysis and electrical characterization of blue light emitting diode", *Proceedings of the Thirty-Seventh Southeastern* 20-22 March 2005, 2005, 73-77
  - [13] Messdaten aus dem Projekt "Performance Quality Label (PQL)" an der Hochschule Hannover, Schwenzfeier-Hellkamp E., Khanh T. Q., Homeyer K., Schierz C.: *Performance Quality Label für LED-Leuchten (PQL) Schlussbericht*, DOI: 10.25968 / opus 635, 2014
  - [14] Wagner M., Herzog A., Ganey H., Khanh T. Q.: "LED aging acceleration – an analysis from measuring and aging data of 14,000 hours LED degradation", *China International Forum on Solid State Lighting; SSLCHINA*, IEEE, ISBN: 978-1-5090-0176-7, 2015
  - [15] IES TM-21-11, "Projecting Long Term Lumen Maintenance of LED Light Sources", ISBN: 978-0-87995-259, 2011
  - [16] Verzellesi, G., Saguatti, D., Meneghini, M., Bertazzi, F., Goano, M., Meneghesso, G. u. Zanoni, E.: Efficiency droop in InGaN/GaN blue light-emitting diodes. Physical mechanisms and remedies. *Journal of Applied Physics* 114 (2013) 7, S. 71101

## Wie Alterungsmodelle für integrierte Transistoren die Entwicklung zuverlässiger Systeme unterstützen

### How degradation models of integrated transistors support the development of reliable electronic systems

Dr.-Ing. **André Lange**, Dr. rer. nat. **Kay-Uwe Giering**,  
Dr.-Ing. **Roland Jancke**,  
Fraunhofer-Institut für Integrierte Schaltungen IIS, Institutsteil  
Entwicklung Adaptiver Systeme EAS, Dresden

#### Kurzfassung

Zuverlässige Systeme können nur aus zuverlässigen Komponenten aufgebaut werden. Deshalb ist die Langlebigkeit auch im Entwurf integrierter Schaltkreise (ICs) eine Anforderung mit wachsender Bedeutung trotz steigendem Kostendruck. Transistoren, die wesentlichen Bausteine von ICs, werden von verschiedenen Degradationsmechanismen beeinflusst. Deren Auswirkungen auf das Verhalten von Schaltungen können durch Alterungssimulationen während der Entwurfsphase, also vor der Fertigung, untersucht werden. Dieser Beitrag stellt die Simulationethodik und die Degradationsmechanismen integrierter Transistoren vor und leitet auf Alterungsmodelle über. Lösungsmöglichkeiten, Anforderungen, erforderliche Messungen, Modellparametrisierung sowie Anknüpfungspunkte zur Zuverlässigkeitsbewertung in anderen Fachgebieten, zum Beispiel im Maschinenbau, werden vorgestellt und ein Ausblick auf zukünftige Entwicklungsmöglichkeiten gegeben.

#### Abstract

Reliable systems can only be realized with reliable components. Thus, reliability has become a requirement in integrated circuit (IC) design as well. Its importance has been rising despite the pressure for cost efficiency. Transistors, the major components of ICs, are affected by multiple degradation mechanisms. Their impact on circuit performance can be virtually investigated by aging simulations in the design phase already, that is before manufacturing. This article introduces the physical mechanisms and the aging simulation methodology. It leads over to the required degradation models and discusses current solution approaches as well as potential future directions with respect to requirements, characterization procedures, pa-

parameter extraction, and links to reliability considerations in other disciplines, such as mechanical engineering.

## 1. Einleitung

Insbesondere in der Automobilelektronik und der Industrieautomation werden hohe Anforderungen an die Zuverlässigkeit elektronischer Systeme gestellt. Produkte in diesen Bereichen müssen über einen langen Zeitraum von 10 Jahren und mehr sowie unter rauen Umgebungsbedingungen funktionieren. Zum Teil werden sie an schwer erreichbaren Stellen verbaut, sodass Reparatur, Wartung oder Austausch einen erheblichen Aufwand verursachen. Die hohen Anforderungen gelten auch für integrierte Schaltkreise (ICs), die wesentliche Bestandteile elektronischer System sind. Ihre Zuverlässigkeit wird mit Zuverlässigkeitstests nachgewiesen. Zum Beispiel muss für Automotive-ICs mindestens der Standard AEC-Q100 [1] befolgt werden.

Ein idealer Ablauf von einer Idee bis zu einem zuverlässigen IC als Produkt ist in Bild 1 dargestellt. Die Zwischenstufe stellen Prototypen dar, die entsprechend getestet werden. Heute werden Schwierigkeiten bezüglich Funktionalität oder Zuverlässigkeit häufig in diesen Tests, z.B. nach AEC-Q100, identifiziert. Sie müssen dann in Re-Designs behoben und durch erneute Tests an Prototypen untersucht werden. Im Jahr 2020 benötigten knapp 70 % aller anwendungsspezifischen ICs ein Re-Design, und in etwa 20 % der Fälle war die Zuverlässigkeit ein Problem [2]. Um Zyklen aus Prototypen, Tests und Re-Designs zu vermeiden bzw. zumindest ihre Anzahl zu verringern, muss in Zukunft die Zuverlässigkeit virtuell bereits in Entwurfsphasen von ICs bewertet werden. Dann werden Probleme frühzeitig identifiziert und vor dem Übergang in die Fertigung behoben. Durch so vermiedene Re-Design-Zyklen können ICs kostengünstiger und schneller entwickelt sowie früher am Markt platziert werden

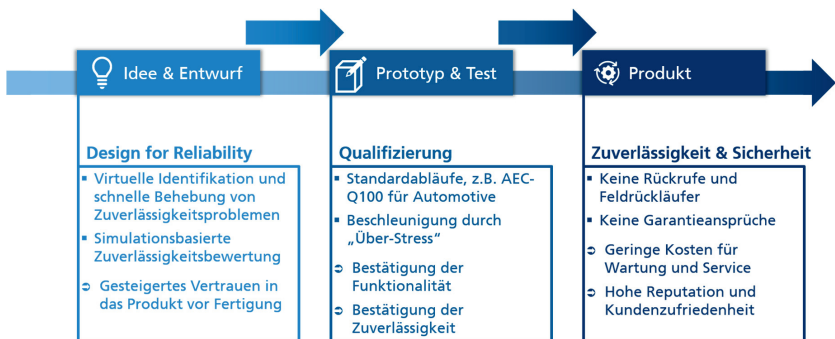


Bild 1: Idealer Ablauf von Idee & Entwurf über Prototyp & Test zum zuverlässigen IC

– und das bei mindestens gleichbleibender Funktionalität und Zuverlässigkeit.

Dafür werden jedoch simulationsbasierte Zuverlässigkeitsbewertungen benötigt. Zum Beispiel untersucht die Alterungssimulation die Auswirkungen der Degradation integrierter Transistoren auf ICs. Dieser Beitrag widmet sich vorrangig den benötigten Modellen für Feldeffekttransistoren (FETs). Dazu wird von den physikalischen Effekten zu Methoden für die Charakterisierung und Beschreibung übergegangen und ein Überblick zum aktuellen Stand und Möglichkeiten der zukünftigen Entwicklung gegeben.

## 2. Qualifizierung von Automotive-ICs nach AEC-Q100

Der Nachweis der Zuverlässigkeit erfolgt für Automotive-ICs mit Messungen, die im Standard AEC-Q100 zusammengefasst sind [1]. Im Wesentlichen kann dabei in zwei Kategorien unterschieden werden: die Produktqualifizierung und die Technologiequalifizierung.

Ein Beispiel für einen Test am Produkt ist der HTOL-Test (High Temperature Operating Life), bei dem eine Stichprobe aus je 77 Produkten aus drei Losen im Betrieb einer erhöhten Temperaturbelastung ausgesetzt wird, z.B. 150 °C für „Grade 0“-Einstufung. Nach 1000 Stunden Belastung müssen alle Stichprobenelemente Funktionstests bei Raumtemperatur sowie hoher und niedriger Temperatur überstehen, damit der HTOL-Test als bestanden gilt. Der Test ist in der Industrie breit akzeptiert, lässt jedoch Fragen offen. Inwiefern ist der verwendete Betriebszustand repräsentativ für den Einsatz des Produkts? Wann würden die ersten Ausfälle auftreten und wie sind diese verteilt? Wie kann man das Testkonzept für Hochtemperatur-Anwendungen erweitern, wenn eine Temperaturbeschleunigung nicht mehr möglich ist? Analysen wie der HTOL-Test werden auch in Zukunft in der Industrie für den Nachweis der Zuverlässigkeit eingesetzt. Für genauere Untersuchungen zu Ursachen und Auswirkungen von Problemen werden sie zukünftig vermutlich nicht ausreichen. Dafür wird eine geeignete Simulationsunterstützung erforderlich.

Die Technologiequalifizierung widmet sich unter anderem der Zuverlässigkeit von Halbleitertechnologien, in denen ICs gefertigt werden. Einer Degradation durch ihren Betrieb unterliegen integrierte Transistoren, z.B. durch Bias Temperature Instability (BTI) sowie Hot Carrier Injection (HCI), und Leiterbahnen, z.B. durch Stress- und Elektromigration. Entsprechende Messungen müssen durchgeführt und dokumentiert werden, wenn eine Technologie nach AEC-Q100 für Automotive-Anwendungen qualifiziert werden soll. Dabei wird nach standardisierten Methoden mit erhöhtem Stress in Form von Spannungen, Strömen und Temperaturen gearbeitet, um die Degradation zu beschleunigen [1],[3]. Beschleunigungsmodelle erlauben eine Worst-Case-Abschätzung der erwarteten Zuverlässigkeit im Betrieb.

### 3. Degradationsmechanismen bei integrierten Feldeffekttransistoren

Von den unterschiedlichen Degradationsmechanismen an Transistoren sind für den Betrieb von ICs insbesondere HCI und BTI von Bedeutung, weil sie die Transistoreigenschaften und damit das Schaltungsverhalten kontinuierlich mit der Zeit verändern. Ihre mikroskopischen Prinzipien sind in Bild 2 dargestellt.

HCI tritt durch einen fließenden Drainstrom  $I_d$  auf, der durch die Drain-Source-Spannung  $V_{ds}$  und die Gate-Source-Spannung  $V_{gs}$  eingestellt wird. Die bewegten Ladungsträger werden zwischen Source und Drain beschleunigt und können irreversible Schäden nahe des Drain-Gebiets hervorrufen [4]. Dadurch nimmt die Ladungsträgerbeweglichkeit  $\mu$  und in Folge dessen der Drainstrom  $I_d$  ab – die Übertragungskennlinie wird wie in Bild 3(a) dargestellt flacher.

Bei BTI unterscheidet man Negative BTI (NBTI) – Degradation eines PFET durch negative Gate-Source-Spannung  $V_{gs}$  – sowie Positive BTI (PBTI) – Degradation eines NFET durch positive Gate-Source-Spannung  $V_{gs}$ . Bei NBTI führt eine negative Gate-Source-Spannung  $V_{gs}$  dazu, dass positive Ladungsträger aus dem Substrat Richtung Gate-Dielektrikum beschleunigt werden.




Bild 2: Schematischer Aufbau von NFET und PFET mit Prinzipdarstellung der Degradationseffekte HCI und NBTI




Bild 3: Prinzipielle Auswirkung von (a) HCI und (b) BTI auf die Übertragungskennlinien von FETs bei konstanter Drain-Source-Spannung  $V_{ds}$ ; (c) typische Kenngrößen zur Charakterisierung der Zuverlässigkeit für einen FET mit 900 mV Betriebsspannung



nigt und in diesem eingefangen werden können [5]. Dadurch wächst der Betrag der Schwellspannung des Transistors, die Übertragungskennlinie verschiebt sich wie in Bild 3(b) zu betragsmäßig größeren Gate-Source-Spannungen  $V_{gs}$ . Die Degradation nimmt mit der Temperatur  $T$  zu. Wird die Belastung reduziert, können die Ladungen wieder freigelassen werden, was einer Erholung, der sogenannten Relaxation bzw. Recovery, entspricht. Dadurch ist NBTI teilweise reversibel. Mit der Einführung von High-k-Metal-Gate-Technologien für Strukturgrößen von ca. 40 nm und darunter hat der Einfluss von PBTI an NFETs zugenommen. Dieser Effekt ist nahezu vollständig reversibel.

Für die Charakterisierung des Einflusses von HCI und BTI werden einzelne Transistoren nach standardisierten Methoden unter konstanter Belastung untersucht [3]. Wie z.B. im Maschinenbau wird mit erhöhter Belastung, aber unverändertem Schädigungsmechanismus gearbeitet. In Messzeiten von üblicherweise  $10^4 \text{ s} \approx 3 \text{ h}$  wird dadurch eine gewisse Degradation erreicht, wobei meist keine vollständigen Kennlinien, sondern bestimmte Kenngrößen daraus ausgewertet werden. Wichtige Vertreter, z.B. der lineare Strom  $I_{dlin}$  und der Sättigungsstrom  $I_{dsat}$  sind in Bild 3(c) illustriert. Die aufgenommenen Daten werden durch Gleichungen beschrieben:

$$(d_{I_{dlin}}, d_{I_{dsat}}, \dots)_{t>0}^{[Mess]} = g(\text{"Belastung"}, \text{"Geometrie"}, T, t) \quad \text{mit der Zeit } t. \quad (1)$$

Ein Beispiel für eine solche Funktion  $g(\cdot)$  ist im Abschnitt 5 angegeben. Dabei enthält die "Belastung" die elektrischen Größen im Betrieb ( $V_{ds}$ ,  $V_{gs}$ ,  $I_d$ ), bzw. eine Auswahl davon. "Geometrie" fasst Informationen über z.B. Länge und Weite eines Transistors zusammen. Auf Basis dieser Beschreibungen kann eine Extrapolation hin zu langen Zeiten und typischer Belastung vorgenommen werden. Dieses Vorgehen ist für HCI etabliert. Es wird auch für BTI genutzt, erfasst dort aber lediglich den permanenten Anteil der Degradation. Soll die Relaxation berücksichtigt werden, sind umfangreichere Messprozeduren erforderlich.

Die Degradation durch HCI und BTI führt in Digitalschaltungen, z.B. Prozessoren, dazu, dass FETs später und langsamer schalten und die Leistungsfähigkeit mit der Zeit abnimmt. Auch analoge Schaltungen sind betroffen, jedoch pauschal weniger vorhersagbar, weil die verwendeten FETs individuell zeitabhängig belastet werden. Die Gegenüberstellung von Spezifikation, zeitabhängiger Änderung der Schaltungseigenschaften und angestrebter Lebensdauer liefert Aussagen darüber, ob die Degradation im konkreten Fall kritisch ist. Insbesondere bei langen Produktlebensdauern, wie in der Automobilelektronik und der Industrieautomation, sind solche Informationen von besonderer Bedeutung.

#### 4. Alterungssimulation

Im Betrieb eines ICs treten an dessen Transistoren nicht-konstante und individuelle Belastungen auf. Deshalb sind die Informationen zu HCI und BTI aus der Technologiequalifizierung, wo mit konstanter Belastung gearbeitet wird, nur bedingt hilfreich. Der Einfluss von HCI und BTI auf das Verhalten des IC während der Nutzungsdauer kann in Alterungssimulationen untersucht werden [6]-[8]. Sie ergänzen gemäß Bild 4 den ohnehin üblichen Ablauf zur Verifikation im IC-Entwurf, beim dem die Schaltung in ein simulierbares Format für den Zeitpunkt  $t = 0$  überführt, ihr Verhalten mit Testbenches für die Evaluierung simuliert und im Vergleich zur Spezifikation bewertet wird. Der Einfluss von HCI und BTI kann ebenso untersucht werden, wenn eine virtuelle Repräsentation der Schaltung nach  $k$  Jahren im Betrieb, z.B. 10-15 Jahre für Automobilanwendungen, vorliegt. Diese kann erzeugt werden, indem ein typisches Nutzungsszenario, das sogenannte Mission Profile, simuliert wird. Aus den Simulationsdaten wird die Belastung ( $V_{gs}$ ,  $V_{ds}$ ,  $I_d$ , ggf.  $T$ ) für jeden FET extrahiert und mit Hilfe eines Alterungsmodells in individuelle Änderungen umgerechnet. Werden diese Änderungen für jeden FET individuell in die Schaltung eingetragen, entsteht die virtuell um  $k$  Jahre gealterte Schaltung. Neben dem Ablauf selbst sind die Mission Profiles und die Alterungsmodelle die zentralen Komponenten für die Alterungssimulation.

#### 5. Alterungsmodelle

##### Nominalmodelle und Anforderungen

Für die Simulation von Schaltungen wird das Verhalten von FETs durch sogenannte Kompaktmodelle beschrieben. Diese verbinden die elektrische, technologische und geometrische Informationen. Ein einfaches Beispiel stellen die Gleichungen [9],[10]

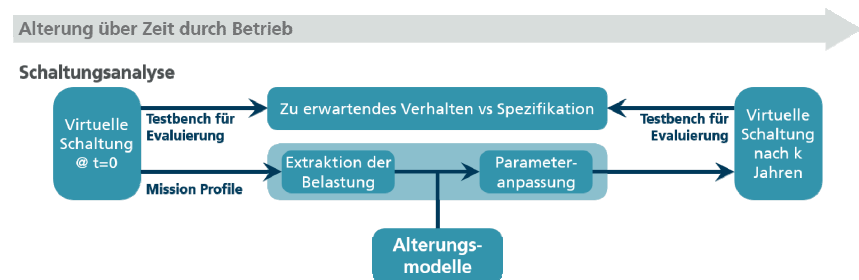


Bild 4: Prinzipieller Ablauf der Alterungssimulation im IC-Entwurf

$$I_d = \begin{cases} I_0 \cdot \exp\left(\frac{V_{gs} - V_{th}}{V_T \cdot n}\right) & V_{gs} < V_{th} \\ \beta \cdot \left([V_{gs} - V_{th}] \cdot V_{ds} - \frac{V_{ds}^2}{2}\right) & V_{th} \leq V_{gs} < V_{ds} \\ \frac{\beta}{2} \cdot (V_{gs} - V_{th})^2 & 0 \leq V_{gs} - V_{th} \leq V_{ds} \end{cases} \quad (2)$$

dar. Dabei sind  $I_0$ ,  $n$ ,  $V_{th}$  und  $\beta$  die Modellparameter, und für die Temperaturspannung  $V_T$  gilt

$$V_T = \frac{k_B \cdot T}{q} \quad (3)$$

mit Boltzmann-Konstante  $k_B$ , Temperatur  $T$  sowie Elementarladung  $q$ . Ein Simulator kann anhand des Kompaktmodells effizient die Kenngrößen des FETs, z.B. den linearen und den Sättigungsstrom, bestimmen,

$$(I_0, n, V_{th}, \beta)_{t=0} \rightarrow (d\_Idlin, d\_Idsat, \dots)_{t=0}^{[Sim]}, \quad (4)$$

die Umkehrung ist allerdings nicht trivial. Für einen FET werden die Parameter des Kompaktmodells so bestimmt, dass gemessenes und simuliertes Verhalten bestmöglich übereinstimmen,

$$\min_{(I_0, n, V_{th}, \beta)_{t=0}} \left\| (d\_Idlin, d\_Idsat, \dots)_{t=0}^{[Sim]} - (d\_Idlin, d\_Idsat, \dots)_{t=0}^{[Mess]} \right\|. \quad (5)$$

Alterungsmodelle stellen die Veränderungen integrierter FETs durch HCI und BTI simulierbar dar. Ein Ansatz verändert ausgewählte Parameter des Kompaktmodells in Abhängigkeit von Belastung und Zeit [11][12]. Im Beispiel von Gleichung (2) sind in erster Näherung die Parameter  $\beta$  und  $V_{th}$  anzupassen, um die Auswirkungen von HCI und BTI nachzustellen:

$$(\beta, V_{th})_{t>0} = f(\text{"Belastung"}, \text{"Geometrie"}, T, t) \quad \text{mit der Zeit } t. \quad (6)$$

Es ist zu beachten, dass Nominalmodelle für hochskalierte Technologien deutlich komplexer sind als die Gleichungen (2) und (3). Sie können mehrere hundert Parameter enthalten.

Alternativ kann die Degradation von FETs durch eine Ersatzschaltung nachgebildet werden. Dabei werden häufig gesteuerte Spannungs- und Stromquellen um den unveränderten Transistor angeordnet. Allerdings vergrößert dieses Vorgehen die Laufzeit von Alterungssimulationen [12].

Unabhängig vom Nominalmodell muss die Funktion  $f(\cdot)$  so gewählt und parametrisiert werden, dass für die vom Simulator ermittelten Kenngrößen  $(d\_Idlin, d\_Idsat, \dots)_{t=0}^{[Sim]}$  die Gleichung (1) bestmöglich erfüllt bleibt. Zudem sind unterschiedliche Nebenbedingungen zu beachten. (a) Die Zuverlässigkeit integrierter Transistoren wird gemäß den in [3] standardisierten Methoden unter konstanter Belastung gemessen, in Betrieb und Alterungssimulation treten jedoch zeitabhängige Belastungen auf. Die Funktion  $f(\cdot)$  muss also zeitabhängige

Spannungen und Ströme auswerten können, was durch geschickte mathematische Formulierungen [13] realisiert werden kann. (b) Mission Profiles für die Alterungssimulation sind aus Gründen des Simulationsaufwandes auf wenige Millisekunden Dauer begrenzt. Es wird angenommen, dass sie periodisch ablaufen, bis die Ziellebensdauer im Bereich von Jahren erreicht ist. Die Funktion  $f(\cdot)$  muss zur effizienten Berechnung eine Zeitextrapolation von der Simulation des Mission Profils zur Ziellebensdauer ermöglichen.

### Ein empirisches Modell für Hot Carrier Injection (HCI)

Die Ableitung eines HCI-Modells wird an einem Beispiel gezeigt. Die zugrundeliegenden Simulationen basieren auf dem Kompaktmodell BSIM4 [14] mit einer Parametrisierung für eine High-k-Metal-Gate-Technologie in 22-nm [15]. Für den betrachteten NFET gelten die Länge  $L = 22$  nm, die Weite  $W = 1$   $\mu$ m und die Betriebsspannung  $V_{dd} = 900$  mV. Zudem werden die Degradation des linearen und des Sättigungsstroms betrachtet und für diese Messwerte die relativen Änderungen gemäß Bild 5 angenommen. Die Daten können mit den Gleichungen

$$d_{Idlin} = \frac{Idlin(t)}{Idlin(t=0)} - 1 = g_1(V_{dstress}, t) = 0,71 \cdot \exp\left(-\frac{5}{V_{dstress}}\right) \cdot t^{0,25} \quad \text{und} \quad (7)$$

$$d_{Idsat} = \frac{Idsat(t)}{Idsat(t=0)} - 1 = g_2(V_{dstress}, t) = 1,56 \cdot \exp\left(-\frac{7}{V_{dstress}}\right) \cdot t^{0,25} \quad (8)$$

beschrieben werden [11]. Die Extrapolation auf  $V_{dstress} = V_{dd} + 10\% = 990$  mV und 10 % Degradation ergibt eine Lebensdauer von 65 h im Hinblick auf den linearen und von 9000 h im Hinblick auf den Sättigungsstrom.

Der Modellansatz ist empirisch in dem Sinne, dass ausgewählte Parameter des zugrundeliegenden Kompaktmodells ohne detaillierte Berücksichtigung der mikroskopischen Mechanismen von HCI so verschoben werden, dass die Messergebnisse in Simulationen nachgestellt

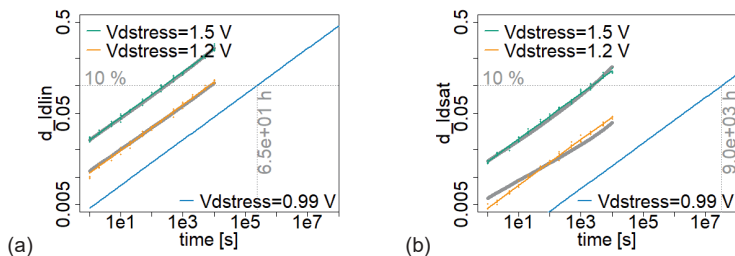


Bild 5: Zuverlässigkeitsdaten für (a)  $I_{dlin}$  und (b)  $I_{dsat}$  unter HCI. Messwerte [Punkte], Approximation durch Gleichung (7) und (8) [farbige Linien], Simulationsergebnisse auf Basis des Alterungsmodells in Gleichung (9) und (10) [graue Linien]

werden können. Im konkreten Fall mit einem Nominalmodell vom Typ BSIM4 verändern wir aus Erfahrung zwei Parameter, die Ladungsträgerbeweglichkeit  $u_0$  und die Sättigungsgeschwindigkeit  $vsat$  [11], hier in der Form der Gleichungen (7) und (8).

$$d_{u_0} = \frac{u_0(t)}{u_0(t=0)} - 1 = f_1(V_{dstress}, t) = -0,834 \cdot \exp\left(-\frac{4,53}{V_{dstress}}\right) \cdot t^{0,236} \quad \text{und} \quad (9)$$

$$d_{vsat} = \frac{vsat(t)}{vsat(t=0)} - 1 = f_2(V_{dstress}, t) = 0,0426 \cdot \exp\left(-\frac{1,78}{V_{dstress}}\right) \cdot t^{0,332} \quad (10)$$

Durch die Verwendung eines Gleichungsansatzes für die Verschiebung der beiden Kompaktmodellparameter ist die Bereitstellung der Modelle in Simulationsumgebungen einfacher. Mit ihnen ergeben sich die in **Fehler! Verweisquelle konnte nicht gefunden werden.** eingetragenen Simulationsergebnisse. Insbesondere für den linearen Strom werden die Messergebnisse nahezu perfekt getroffen. Beim Sättigungsstrom sind insbesondere bei geringerer Belastung Abweichungen festzustellen. Die Genauigkeit kann verbessert werden, indem für die Sättigungsgeschwindigkeit ein alternativer Gleichungsansatz statt (10) verwendet wird. Dadurch wachsen jedoch die Modellkomplexität und der Aufwand.

In den Ansätzen für die Gleichungen sowie in der Art und Anzahl der Kenngrößen und Einflussfaktoren bestehen wesentliche Freiheitsgrade für empirische Alterungsmodelle. Je mehr Kenngrößen, Beispiele sind in Bild 3(c) illustriert, berücksichtigt werden müssen, desto mehr Kompaktmodellparameter müssen im Alterungsmodell angepasst, desto mehr Gleichungen also aufgestellt werden. Werden in diese dann mehr Einflussgrößen aufgenommen, wachsen die Gleichungen um entsprechende Terme. Zum Beispiel könnte eine Temperaturabhängigkeit eingefügt werden, was üblicherweise über einen Arrhenius-Term  $\exp\left(\frac{E_a}{k_B T}\right)$  mit der der Aktivierungsenergie  $E_a$  geschieht. Als ein anderes Beispiel ist die Frequenz als Einflussgröße bei Höchsfrequenzanwendungen ein aktuelles Forschungsthema.

### Ein physikbasiertes Modell für NBTI

Als ein Ansatz zur Modellierung von NBTI wird an dieser Stelle ein physikbasiertes Modell vorgestellt [16]. Im Gegensatz zu empirischen Ansätzen basiert es auf den im Kapitel 3 vorgestellten mikroskopischen Mechanismen des Einfangens und Freilassens von Ladungsträgern an bestehenden oder neu entstehenden Defekten im Gate-Dielektrikum, also dessen Auf- und Entladen. Ein geladener Defekt verschiebt insbesondere die Schwellspannung des Transistors  $V_{th}$ , das Entladen führt zur Relaxation. Diese Physik kann durch ein Markov-Zweizustandsmodell für Grenzflächen- sowie Gate-Oxid-Defekte modelliert werden [16]. Wie in Bild 6(a) schematisch dargestellt geht ein Defekt vom neutralen Zustand „1“ in den geladenen Zustand „2“ mit einer mittleren sogenannten Capture-Zeit  $\tau_c$  über und kehrt mit einer




Bild 6: (a) Illustration des Zweizustandsmodells; (b) Experimentelle Daten zur Verschiebung der Schwellspannung  $\Delta V_{th}$  beim Wechsel zwischen Stress und Relaxation; (c) Beispielhafte Güte der Modellparametrisierung, Vergleich von Messung (Punkte) und Simulation (Linien) für getrennt dargestellte Phasen von Stress und Relaxation [16]

mittleren Emission-Zeit  $\tau_e$  zurück. Diese charakteristischen Zeiten sind defekt-spezifisch und abhängig von Spannung (insbesondere  $V_{gs}$ ) sowie Temperatur. Das Markov-Modell beschreibt die Defekt-Dynamik über eine gewöhnliche Differentialgleichung mit zeitabhängigen Parametern, die für in Schaltungssimulationen wichtige Fälle numerisch effizient gelöst werden kann [17]. Die Integration über alle Defekte liefert schließlich die zeitabhängigen Transistorparameter.

Das Modell wird durch spezielle ultraschnelle BTI-Messungen parametrisiert. Dabei werden FETs durch wechselnde Stressmuster, z.B. wie in Bild 6(b), bei unterschiedlichen Temperaturen  $T$  und Werten für die Gate-Source-Spannung  $V_{gs}$  charakterisiert. Die freien Parameter, insbesondere die Dichte, energetischen Eigenschaften sowie Zeitkonstanten der Defekte  $\tau_c$  und  $\tau_e$ , werden so bestimmt, dass Messung und Simulation wie in Bild 6(c) möglichst übereinstimmen. Durch seine Genauigkeit und Universalität kann das Modell bei der Analyse unterschiedlicher Schaltungstypen eingesetzt werden, u.a. für analoge Grundschaltungen [18], Ringoszillatoren [16] und Speicherzellen [19].

## 6. Zusammenfassung

Im Entwurf integrierter Schaltkreise (IC) steht mit der Alterungssimulation eine Methode zur Verfügung, mit dem Entwickler die Zuverlässigkeit ihrer Schaltungen virtuell und vor der Übergabe an die Fertigung überprüfen können. Dadurch wird die Langlebigkeit von ICs und den darauf aufbauenden elektronischen Systemen sichergestellt und ein Beitrag zum zuverlässigen Betrieb geleistet. Das ist insbesondere für Anwendungen im Automobilbereich und

der Industrieautomation von Interesse, wo lange Produktlebensdauern unter z.T. rauen Bedingungen erreicht werden müssen.

Als Basis von Alterungssimulationen bilden Alterungsmodelle die Auswirkungen von Degradationsmechanismen, insbesondere Hot Carrier Injection (HCI) und Bias Temperature Instability (BTI), auf integrierte Feldeffekttransistoren (FET) simulierbar ab. Dafür werden empirische und physikbasierte Ansätze verwendet. Empirische Modelle sind meist einfacher handhabbar, physikbasierte dafür genauer. Ihnen ist gemeinsam, dass sie mit Daten aus Zuverlässigkeitsmessungen parametrisiert werden. In diesen Experimenten wird die Degradation durch hohe Belastungen beschleunigt und dann auf typische Szenarien in der Nutzung umgerechnet. Wie in anderen Disziplinen der Zuverlässigkeitsanalyse muss dabei berücksichtigt werden, dass sich die auftretenden Schadensmechanismen nicht ändern.

In unserer Wahrnehmung werden Alterungssimulationen zunehmend häufig eingesetzt. Dadurch werden auch Erweiterungen und Verbesserungen der Alterungsmodelle erforderlich. Bisher werden verschiedenste Ansätze eingesetzt. Insbesondere Entwickler zuverlässiger Elektronik bringen neue Anforderungen, z.B. im Hinblick auf die Genauigkeit und die Berücksichtigung zusätzlicher Einflussfaktoren, ein. Halbleiterhersteller werden diesen mit verbesserten eigenen oder vereinheitlichten Lösungen begegnen.

## Danksagung

Wesentliche Teile dieses Beitrags sind mit Förderung durch den Freistaat Sachsen sowie den Europäischen Fonds für Regionale Entwicklung (EFRE) im Projekt ARAMID (Sächsische Aufbaubank (SAB), FKZ 100375234) entstanden.

## Referenzen

- [1] Automotive Electronics Council: AEC-Q100 – Failure Mechanism Based Stress Test Qualification For Integrated Circuits. Rev. H, 11.09.2014.  
<http://www.aecouncil.com/AECDocuments.html>
- [2] Foster, H.: Part 12: The 2020 Wilson Research Group Functional Verification Study. Blog-Beitrag, <https://blogs.sw.siemens.com/verificationhorizons/2021/02/03/part-12-the-2020-wilson-research-group-functional-verification-study>, 03.02.2021, abgerufen am 10.02.2021.
- [3] JEDEC Solid State Technology Association, <https://www.jedec.org/>
- [4] Chen, K.-L. et al.: Reliability Effects on MOS Transistors Due to Hot-Carrier Injection. IEEE Transactions on Electron Devices, 32(2), S. 386-393, Feb. 1985.

- [5] Grasser, T.: Stochastic charge trapping in oxides: From random telegraph noise to bias temperature instabilities. *Microelectronics Reliability*, 52(1), S. 39-70, Jan. 2012.
- [6] Schaldenbrand, A.: *Analog Reliability Analysis for Mission-Critical Applications*, White Paper, Cadence Design Systems, Inc, 2019.
- [7] Selim, M.; Jeandeau, E.; Descleves, C.: *Addressing IC Reliability Issues Using Eldo*, White Paper, Mentor Graphics Corporation, 2016.
- [8] Tudor, B. et al.: *MOS Device Aging Analysis with HSPICE and CustomSim*, White Paper, Synopsys, Inc, 2011.
- [9] Göbel, H.: *Einführung in die Halbleiter-Schaltungstechnik*. 5. Auflage, Berlin: Springer Vieweg 2014.
- [10] <https://de.wikipedia.org/wiki/Metall-Oxid-Halbleiter-Feldeffekttransistor>, abgerufen am 09.02.2021.
- [11] Lange, A. und Jancke, R.: Challenges and solution approaches for simulation-based reliability assessment - degradation modeling. *IEEE International Integrated Reliability Workshop (IIRW)*, 2020.
- [12] Lange, A. et al.: Comparison of modeling approaches for transistor degradation: Model card adaptations vs subcircuits. *IEEE European Solid-State Device Research Conference (ESSDERC)*, 2019.
- [13] Scholten, A.J. et al.: The Relation Between Degradation Under DC and RF Stress Conditions. *IEEE Transactions on Electron Devices*, 58(8), S. 2721-2728, Aug. 2011.
- [14] University of California, Berkeley, BSIM Group: BSIM4 Model. <https://bsim.berkeley.edu/models/bsim4/>, abgerufen am 25.01.2021.
- [15] Nanoscale Integration and Modeling (NIMO) Group, Arizona State University: Predictive Technology Model - 22nm PTM LP model. [http://ptm.asu.edu/modelcard/LP/22nm\\_LP.pm](http://ptm.asu.edu/modelcard/LP/22nm_LP.pm), 15.11.2008, abgerufen am 25.01.2021.
- [16] Giering, K.-U. et al.: NBTI Degradation and Recovery in Analog Circuits: Accurate and Efficient Circuit-Level Modeling. *IEEE Transactions on Electron Devices*, 66(4), S. 1662-1668, Apr. 2019.
- [17] Giering, K.-U. et al.: NBTI modeling in analog circuits and its application to long-term aging simulations. *IEEE International Integrated Reliability Workshop (IIRW)*, 2014.
- [18] Giering, K.-U. et al.: Analog-circuit NBTI degradation. *IEEE International Reliability Physics Symposium (IRPS)*, 2016.
- [19] Giering, K.-U. et al.: BTI variability of SRAM cells under periodically changing stress profiles. *IEEE International Integrated Reliability Workshop (IIRW)*, 2016.



# **Cross-domain reliability analysis from individual components to the entire system during development using the example of a lithium-ion battery cell**

## **Entwicklungsbegleitende domänenübergreifende Zuverlässigkeitsanalyse von Einzelkomponenten bis hin zum Gesamtsystem am Beispiel einer Lithium-Ionen-Batteriezele**

M.Sc. **Simon Kupjetz**, Dipl.-Ing. **Thomas Pfeiffer**,  
B. Eng. **Johannes Holz**, Fraunhofer Institute for Structural Durability  
and System Reliability LBF, Darmstadt

### **Abstract**

Using the development of a lithium-ion cell as an example, an analysis of the reliability of individual components is carried out during development. For example, the effect of newly developed anode materials on the reliability of the entire system can be determined. If data are available, the effect of design specifications on (system) reliability can be calculated quantitatively down to the battery module. With the help of Bayesian Networks, the logical linking of the failure modes with quantitative failure rates from the individual component to the battery cell is represented. For the optimization process of individual components, the effect in the battery module can thus be calculated directly. This is particularly necessary because different developers are usually involved in the various sub-domains for the individual components of a lithium-ion cell. This makes it possible to keep the focus on the reliability of the overall system across company boundaries. Particularly regarding of the current increased development of battery cells without the use of critical raw materials such as cobalt, it is important to evaluate new alternatives directly in the development process, not only in terms of performance, but also in terms of reliability.

### **1. Introduction and motivation**

Further product developments of complex technical systems are particularly challenging in terms of system reliability and safety. This is especially more likely when fundamental changes are made in different domains. It becomes even more complex when different developers implement changes in different parts or subcomponents of the technical system in the early phase of the design process. Often there are dependencies between different domains with significant effects on reliability. Keeping track of these different changes is challenging in terms of different areas such as mechanics, electrics, chemistry and different developers of the companies involved. Using the example of the development of a cobalt-free lithium-ion battery

in the EU project COBRA (COBalt-free Batteries for FutuRe Automotive Applications), a method to address the challenges mentioned before is demonstrated. Additionally, the description and tracking of quantitative reliability data over the design process of different generations of the cell and battery pack is shown. The project calls for a holistic approach to address the many challenges associated with the development of reliable lithium ion batteries. With the method, the effects of individual changes on the overall system can be represented and calculated, which supports the development of a novel, reliable, cobalt-free lithium-ion battery.

2. Introduction to Bayesian Networks

Bayesian Networks belong to the family of probabilistic graphical models and are directed acyclic graphs. They can visualize knowledge about an uncertain domain [1]. Each node of the graph represents a random variable with at least two discrete states. Each edge represents dependencies between the related random variables. These conditional dependencies can be estimated using numerical and statistical methods. In order to express conditional probabilities of a single variable in dependence on others, Bayesian networks use Conditional Probability Tables (CPT). Bayesian Networks are used, for example, in the field of artificial intelligence [2]. A number of solving algorithms for the exact or approximate solution of BN have been developed throughout the recent decades such as the variable elimination (VE) algorithm [1].




Figure 1: Bayesian Network with conditional probability tables

With the help of a fictitious graph, which can be seen in figure 1, the principle of Bayesian Networks is explained. CPTs are used here to express conditional probabilities (true = T, false = F) and its associated probabilities (0 – 1) of a discrete state. Whether the sun is shining or not and whether there is wind are mutually exclusive states of the random variables. These represent evidences which occur with a certain probability during a fictitious time span of three

hours. In the example case wet clothes that have been hung out to dry will dry during this period if the sun is shining on the clothes and it is windy. The sun is to hit on the photovoltaic system from the right angle to convert enough sunlight into electricity in order to charge a scooter battery, for example. This outcome is independent of whether there is wind.

### 3. Introduction of safety methods for technical systems

To determine the reliability of a system in a qualitative analytical way, various methods are available, such as Failure Mode and Effects Analysis (FMEA), Fault Tree Analysis (FTA) and event sequence analysis [3]. To assess reliability, this can be done either with a bottom up or top down approach. Bottom up means that this is carried out through the hierarchy levels starting with the components or subcomponents up to the overall system. For this, failure modes for sub-components are being determined and their effects and consequences concluded with respect to the group of integrated sub-components. In the top-down approach, the failure search in the system is carried out starting with the system to identify possible causes in the lower hierarchical levels. FMEA is a systematic bottom-up method to determine all potential failure modes, failure effects and failure causes for components or (sub-)systems. The risk is determined and recommended actions for optimisation are defined. For each failure mode, it is qualitatively determined how likely the occurrence of a failure mode is, how severe the consequences are and how likely the cause is detected [3]. Based on the FMEA, the failure modes, mechanisms and effects analysis (FMMEA) was developed, which follows a physics of failure approach. The FMMEA approach can be used to gain a better understanding of the failure mechanisms and physics-of-failure that lead to failure modes [4].

FTA is an analytical top-down technique that defines an unintended state of the system (top level event) that predominantly is critical from a reliability or safety perspective. The system is then analysed in the context of the environment and operation to determine the ways in which this top level event can occur. With the help of a graphical model represented by the FTA, various parallel and sequential fault combinations that lead to the top level event can be identified and displayed. To evaluate FTAs, minimal cut sets (MCS) are usually created, i.e. the smallest possible combination of basic events that trigger the top level event. In particular, MCSs triggered by only one fault or event are to be avoided. Fault trees can also be evaluated quantitatively by specifying the probabilities for the occurrence of basic events for each MCS and adding up the probabilities of the individual MCSs that lead to the top level event [5]. The results of the calculations with MCS can deviate from the exact probabilities and must therefore be viewed with caution or generated with other evaluation algorithms [6].

Since FMEA does not allow quantitative evaluation, FTA does not allow a coherent holistic representation of the system Kaiser and Rauschenbach [7], [8] proposed a concept for

quantitative FMEA called probFMEA which can be modeled and solved based on Bayesian Networks. Bayesian Networks are used for this purpose, which provide the algebraic basis to allow the quantitative assessment of reliability.

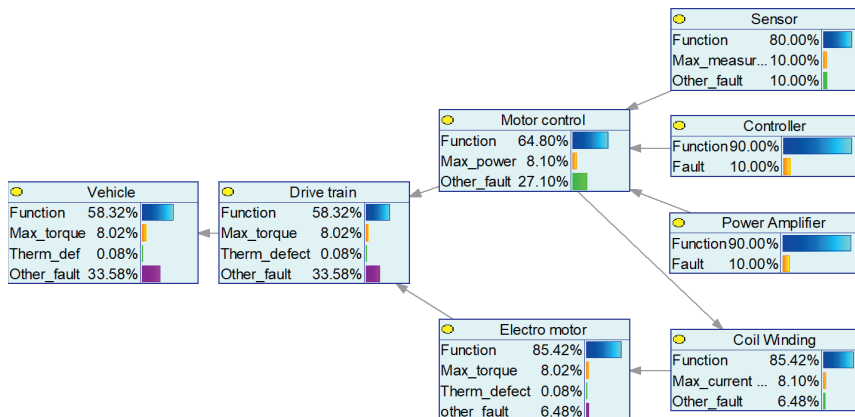


Figure 2: Example of a cascade fault as a conditionally independent consequential effect modelled with Bayesian Networks [8]

An exemplary failure network of an electric vehicle based on Bayesian Networks is shown in Figure 2. If a malfunction occurs in a component, e.g. in a sensor, the condition is propagated to the next higher hierarchy level (motor control) and then to the drive system and finally to the vehicle level. A cascading fault was realized as a conditionally independent consequential effect [8] in this example.




Figure 3: Quality and significance of the data depending on the available data

The significance of the Bayesian Network depends on the quality of the available data for the failure modes, the logical cause-effect relationships, and the corresponding failure probabilities. At the beginning of the network creation, when not enough failure probabilities are available, a rough estimation is made to understand the cause-effect relationships. As the development of a product progresses, more data gradually becomes available, as can be seen in figure 3, and the network becomes more significant.

#### 4. Design of lithium-ion batteries he cell upwards

A conventional lithium-ion cell consists of a lithium-based cathode, a carbon-based anode, electrolytes and a separator, as shown in figure 4. Usually, the cathode material is bonded to an aluminium foil and the anode material to a copper foil, both of which act as current collectors. The electrolyte consists of soluble salts, acids or other bases in the liquid and dry polymer. A piece of porous polymer serves as a separator and is located between the anode and cathode. The separator is immersed in the electrolyte and serves as prevention against a short circuit between the two electrodes. During operation, lithium-ions undergo a cycle of intercalation and deintercalation and move as charge carriers through the electrolyte in the internal circuit. The intercalation of the lithium-ions into the anode needs an external energy and the deintercalation happens spontaneously. During this process of the lithium-ions, redox reactions occur at the electrodes, which generate electrons that form a current through the external circuit. The migration of the lithium-ions in the internal circuit and the migration of the electrons in the external circuit enables the battery to operate [9].




Figure 4: Basic structure of a lithium-ion battery cell based on [12]

Since individual cells cannot provide the necessary power for applications in electrified vehicles, for example, several cells are electrically and mechanically interconnected to form modules. Modules usually contain electrical and thermal sensors and interfaces. The mechanical and electrical assembly of several modules is called a battery pack, which usually contains hardware and software for thermal and electrical control. By combining the modules into a battery pack, the necessary power and energy for electric vehicles can be provided. In

the automotive context, battery packs are embedded in the existing crash safety structure and communicate with the vehicle electronics to operate the cells with the intended operating parameters in terms of safety and lifetime [10].

In [11], [12] the most important degradation mechanisms in lithium-ion battery cells that occur during operation and exposure to environmental conditions were summarized.

While some failure modes can be attributed to wear during operation, certain failure modes are due to overstress. These can be attributed to operation outside the defined operating conditions as e.g. deep discharge or environmental conditions as e.g. mechanical stress. Hendricks [12] has divided the observed effects caused by the failure modes of the ten cell components into thirteen types. Some of these imply a reduction in performance (e.g. reduced cell capacity) while others have safety-critical consequences such as a thermal runaway. To avoid premature degradation and catastrophic failure, constant monitoring and control of the lithium-ion battery is essential. Without proper control of operating conditions, the battery system is prone to failures that can cause explosions, fire, toxic gas emissions or other negative consequences for both humans and the environment.

## 5. Application of the probabilistic FMEA

Based on a FMMEA of a lithium-ion battery cell from Hendricks [12] and the probFMEA approach from Rauschenbach [8] a Bayesian Network with logical connections between the failure modes of battery components and the observed effects on cell level is created with the software GeNIe® Modeler from BayesFusion which is shown in figure 5. Instead of each battery component being a separate node with its associated failure modes as shown in figure 2, each failure mode has been given its own node to facilitate the graph handling. Based on this Bayesian Network, a qualitative and quantitative analysis of the reliability of a lithium-ion cell can thus be carried out. To limit the dimensions of the created CPTs, additional nodes are inserted which have no effect on the calculated results. Instead, these serve for a systematic bundling of inferences related with specific functional consequences, such as reduction of capacity or power or increased diffusion resistance. In order to increase the manageability and clarity of the graphs, the components with its failure modes are grouped into sub models.

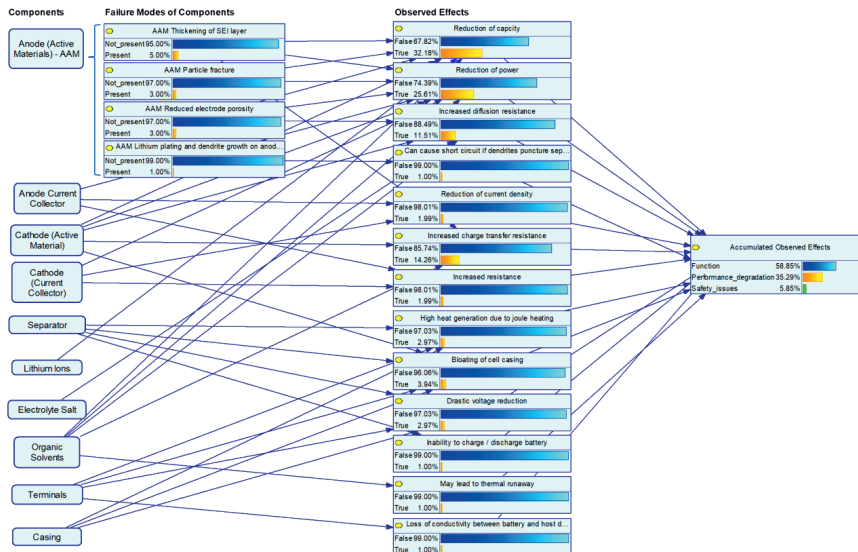


Figure 5: Bayesian Network with failure modes of a lithium-ion cell with fictitious failure probabilities

Since the technology of lithium-ion batteries is not entirely new, data from existing systems or from literature can be obtained to refine the Bayesian Network. In the next step, the developers of the components and materials can make initial statements about how high the failure probabilities are and which cause-effect relationships exist. In order to validate and verify the generated failure networks and failure probabilities, component tests, integration tests and system tests are to be carried out. As the number of tests increases, the Bayesian Network can be updated in a recursive manner with more accurate data. Due to the lack of precise data for failure probabilities the shown percentages are derived from Hendricks FMMEA based on reliability testing, battery disassembly and failure analysis with its division into high/moderate/low likelihood of failure occurrence in the battery lifetime [12]. Failures of the identified components can lead to various observed effects on cell level which are grouped into several categories based on their impact on the cell (function / performance degradation / safety issues). Section 4 explained how the use of sensors and control of operating conditions in the BMS of a battery pack can result in less catastrophic consequences than those depicted in the Bayesian network of a single cell shown in figure 5. As the failure probabilities depend heavily on the use cases and load profiles as well as the environment types in which the battery is being operated, these parameters need to be determined for a more accurate result.

Because of the nature of the Bayesian Networks, the presented methodology can be extended across several hierarchical levels of a battery system from component level up to the battery pack level as outlined in figure 6. In the context of electric driving, this can be continued up to the vehicle level.

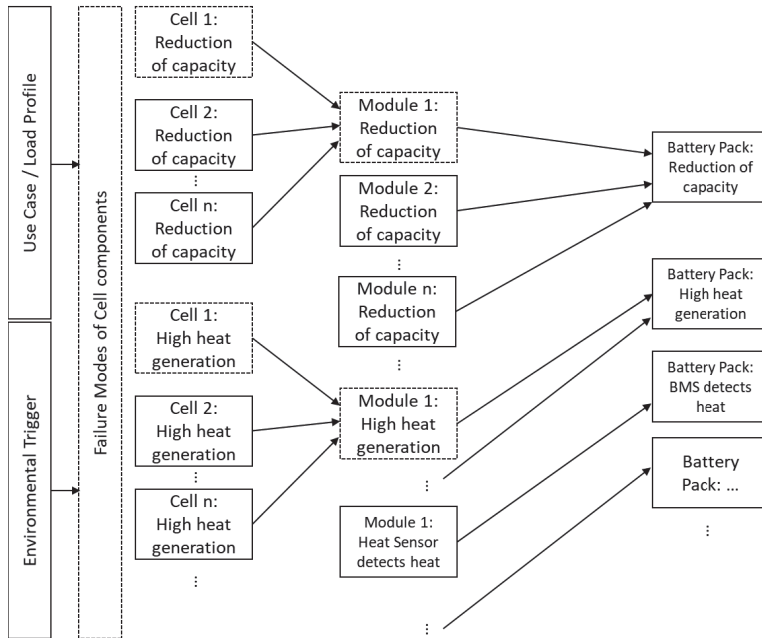


Figure 6: Outline - Extension of the Bayesian Network with observed effects on module and battery pack level

The blocks highlighted with dotted lines were discussed in detail in the previous section. The related failure modes per cell can be collected and accumulated for each failure symptom addressed per module and subsequently per battery pack to estimate the failure probabilities of the whole battery system. The propagation of failures in individual cell components can thus be modelled up to the top level. If sensors are installed at module or battery pack level to detect faults, this can also be taken into account in the model. Depending on the use case and load profile, e.g. operating the battery close to the design limit can have a negative impact on the reliability and safety of the individual components. This can be taken into calculation of the Bayesian Network in addition to the influence of environmental conditions such as extremely low ambient temperature.



Figure 7 shows how the development of new materials or components can affect the probabilities of the observed effects under the assumption that all components not shown do not change its failure modes and probabilities. In this fictitious example, the impacts of a newly developed anode material and a new organic solvent on the observed cell-level effects are modelled. An important capability of modelling with Bayesian Networks is the fact that comparisons between different model generations can be made visually and numerically to measure the progress of the project. It can happen that on the one hand the performance is increased due to the use of new components. But on the other hand the probability of a critical condition (e.g. high heat generation) may increase at the same time. If this condition can be avoided through the smart use of sensors and risk mitigation by a battery management system (BMS), the net result is a gain in performance without a loss in safety. This methodology makes it possible to address different areas such as mechanics, electrics, chemistry and the different developers of the companies involved and quantify the safety and reliability of newly developed products. When used in the early concept phase, this tool can help make design decisions that affect reliability and safety, contributing to the development of a safer product. At the points where the presented methodology identifies vulnerabilities, developers can implement failsafe and mitigation measures that would prevent an undesirable state of the battery cell.

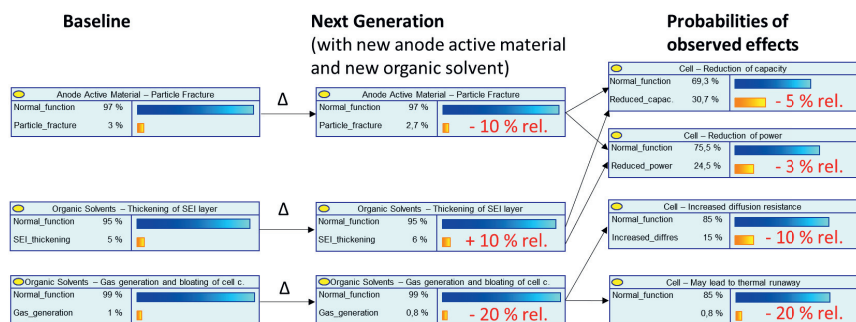


Figure 7: Comparison of two battery material generations and the observed effects

Besides the incremental change of probabilities, the failure modes can also be set to completely true or not true, in order to determine the possible consequences. A major advantage of Bayesian Networks is their use for reversed evaluation from specific observed symptoms to the likelihood of possible causes, termed as back propagation.

Table 1 (left): Most likely Failure Modes with its associated fictitious probabilities when *Increased Diffusion Resistance* (IDR) is present - Table 2 (right): Observed effects that occur simultaneously as an impact of IDR

Component	Potential Failure Mode	P [%]	Observed Effect	P [%]
Organic Solvents	Gas generation and bloating of cell casing	43.45	Increased diffusion resistance	100
Anode (Active Material)	Reduced electrode porosity	26.07	Reduction of capacity	64.94
Cathode (Active Material)	Reduced electrode porosity	23.07	Reduction of power	61.54
Organic Solvents	Thickening of solid electrolyte interphase layer	8.69	Increased charge transfer resistance	14.26
			May lead to thermal runaway	8.69

In this fictitious example, increased diffusion resistance was assumed to be true ( $P = 100\%$ ). Based on the fault network presented at the beginning, the most probable failure modes can be determined sorted according to their occurrence probabilities, which can be seen in table 1. Since a large part of the observed effects do not occur alone, side effects can be identified, sorted by probability of occurrence, as shown in table 2 to have a better understanding of the mechanisms.

## 6. Summary and outlook

In this work, a methodology was presented to analyse the reliability and safety of a lithium-ion battery cell. Logical relationships between failure modes and observed effects were created in a Bayesian Network. With this approach, it is possible to qualitatively and quantitatively assess as well as visually display the reliability and safety of further developments across different domains during product development. Depending on the availability of data, incremental changes to individual components and their effects on the cell can thus be determined. In the COBRA project, the approach will be pursued to reveal weaknesses and to monitor the development of a safe and reliable cobalt-free battery across different battery generations. For this step, the Bayesian Network is extended to module and battery pack level, including fail safe mechanisms and risk mitigation strategies. Using selected components as examples, a comparison between a state of the art battery containing cobalt and a cobalt-free battery will be yielded. In order to be able to make more accurate assessments, data from laboratory tests

and validation tests of the cell, modules and also the battery pack will be used. The methodology shown here is not limited to the development process of batteries, but is applicable to a wide range of complex technical systems, such as autonomous driving or systems with fuel cells.



**Funding:** This project has received funding from the European Union's Horizon 2020 research and innovation programme under grant agreement No 875568.

**Acknowledgments:** We thank the battery experts M. Sc. Melina Hadjebi and M. Eng. Christian Geisbauer for their advisory role. Furthermore, we would like to thank the safety experts Dr. Matthias Rauschenbach and Dr. Jürgen Nuffer for their expert advice and their comments on the manuscript.

## References

- [1] Pearl, Judea (1988): Probabilistic Reasoning in Intelligent Systems. Networks of Plausible Inference. s.l.: Elsevier Reference Monographs
- [2] Ben-Gal, Irad (2007): Bayesian Networks. In: Fabrizio Ruggeri (Hg.): Encyclopedia of statistics in quality and reliability. Chichester: Wiley.
- [3] Bertsche, Bernd (2008): Reliability in Automotive and Mechanical Engineering. Berlin, Heidelberg: Springer-Verlag GmbH
- [4] Mathew, Sony; Alam, Mohammed; Pecht, Michael (2012): Identification Of Failure Mechanisms To Enhance Prognostic Outcomes. In Journal of Failure Analysis and Prevention 12 (1), 66-73.
- [5] Stamatelatos, M.; Vesley, W. (2002): Fault tree handbook with aerospace applications. Washington: NASA Office of Safety and Mission Assurance / NASA Headquarters.
- [6] S. Epstein; A. Rauzy (2005): Can we trust PRA? In Reliability Engineering & System Safety 88 (3), pp. 195–205. DOI: 10.1016/j.ress.2004.07.013.
- [7] Kaiser, B.; Rauschenbach, M. (2015): Probabilistic extension of failure net based FMEA. In: Proceedings of the 25th European Safety and Reliability Conference, ESREL 2015, Zürich, Switzerland, 7-10 September 2015. Boca Raton, London, New York: CRC Press Taylor & Francis Group a Balkema book, pp. 1359–1366.
- [8] Rauschenbach, Matthias (2017): Probabilistische Grundlage zur Darstellung integraler Mehrzustands-Fehlermodelle komplexer technischer Systeme. Technische Universität, Darmstadt. Available online at <http://tuprints.ulb.tu-darmstadt.de/6920/>.

- [9] Ma, Shuai; Jiang, Modi; Tao, Peng; Song, Chengyi; Wu, Jianbo; Wang, Jun et al. (2018): Temperature effect and thermal impact in lithium-ion batteries: A review. In *Progress in Natural Science: Materials International* 28 (6), pp. 653–666. DOI: 10.1016/j.pnsc.2018.11.002.
- [10] Pistoia, Gianfranco; Liaw, Boryann (Eds.) (2018): *Behaviour of Lithium-Ion Batteries in Electric Vehicles. Battery Health, Performance, Safety, and Cost*. Cham: Springer (Green Energy and Technology).
- [11] Birkel, Christoph R.; Roberts, Matthew R.; McTurk, Euan; Bruce, Peter G.; Howey, David A. (2017): Degradation diagnostics for lithium ion cells. In *Journal of Power Sources* 341, pp. 373–386. DOI: 10.1016/j.jpowsour.2016.12.011.
- [12] Hendricks, Christopher; Williard, Nick; Mathew, Sony; Pecht, Michael (2015): A failure modes, mechanisms, and effects analysis (FMMEA) of lithium-ion batteries. In: *Journal of Power Sources* 297, S. 113–120. DOI: 10.1016/j.jpowsour.2015.07.100.

## Zuverlässigkeitsanalyse von PV-Anlagen und Wechselrichtern

M.Sc. **A. Benz**, M.Sc. **K. Hintz**, M.Sc. **M. Diesch**, Dr.-Ing. **M. Dazer**,  
Prof. Dr.-Ing. **B. Bertsche**,  
Institut für Maschinenelemente, Universität Stuttgart;  
Dipl.-Phys. **J. Knoch**, Electronicon Kondensator GmbH, Gera;  
Dipl.-Ing. **D. Clemens**, SMA Solar Technology AG, Niestetal

### Kurzfassung

Die Lebensdauieranforderungen an die Elektronik sind im Bereich der Photovoltaik mit über 20 Jahren sehr hoch. Gleichzeitig unterliegt der Markt einem hohen Wettbewerbsdruck, weshalb die Kosten von PV-Anlagen immer weiter gesenkt werden müssen. Um die Lebensdauerziele bei gleichzeitiger Kostenreduktion zu erreichen, ist eine systematische Zuverlässigkeitsbetrachtung der PV-Anlagen-Elektronik notwendig. In diesem Bericht wird ein Zuverlässigkeitsprozess zur Lebensdauerabsicherung von Elektronik an PV-Anlagen vorgestellt, bei welchem die Ziele aus dem Produktentstehungsprozess (PEP) integriert sind. Zunächst werden unterschiedliche PV-Anlagen-Konzepte analysiert, um die Auswirkungen der Ausfälle einzelner Teilsysteme auf das Gesamtsystem PV-Anlage zu bewerten und kritische Teilsysteme aufzudecken. Dabei wird der Wechselrichter aus der Zuverlässigkeitsperspektive als ein kritisches Teilsystem der PV-Anlage identifiziert. Je nach Konzept fällt die Systemarchitektur sowie die Belastung der Elektronik im Wechselrichter unterschiedlich aus. Um die kritischen Baugruppen und Komponenten des Wechselrichters abzusichern sowie Potentiale zur Kosteneinsparung durch Vermeidung von Überdimensionierungen aufzudecken, wird der Zuverlässigkeitsprozess am Beispiel des Mono-String-Wechselrichters aufgezeigt. Hierfür werden interne und externe Wechselwirkungen des Wechselrichters ermittelt und Zuverlässigkeitsblockschaltbilder für die Hauptfunktionen abgeleitet. In einer ABC-Analyse werden die kritischen Baugruppen identifiziert und anhand einer Priorisierung die Komponenten für Versuche zur Ermittlung und Parametrisierung von Lebensdauermodellen gewählt. Um die aus der Fehlerbaumanalyse für die Komponenten relevanten Ausfallmechanismen voneinander abzugrenzen, sind für das weitere Vorgehen Lebensdauerversuche durchzuführen.

## 1 Motivation

Als Antwort auf die fortschreitende Verknappung der fossilen Energieträger und den bei Verbrauch unmittelbar verbundenen negativen Einfluss auf den Klimawandel soll laut Koalitionsvertrag aus dem Jahr 2018, der Anteil der Erneuerbaren Energien am Bruttostromverbrauch bis 2030 auf 65% angehoben werden [1]. Dabei nimmt die Photovoltaik (PV) eine Schlüsselrolle ein, welche die Solarstrahlung emissionsfrei in elektrische Energie umwandelt und auf diese Weise die Sonnenenergie dezentral nutzbar macht. Um dieses Ziel zu erreichen, muss der wirtschaftliche Betrieb von PV-Anlagen im Wohnbereich gewährleistet sein. Dieser hängt stark von den Anschaffungs- und Instandhaltungskosten sowie dem Energieertrag ab, was wiederum unmittelbar mit der Zuverlässigkeit und Verfügbarkeit der Anlage einhergeht. Um die Anschaffungskosten zu optimieren, müssen Überdimensionierungen vermieden werden, was sich negativ auf die Zuverlässigkeit und den damit verbundenen Ertrag sowie die Instandhaltungskosten auswirken kann. Gleichzeitig sollen die Anlagen aber einer Lebensdauerausforderung von über 20 Jahren standhalten.

Im Wohnbereich werden unterschiedliche Konzepte von PV-Anlagen verwendet, bei denen die Leistungselektronik in unterschiedlichen Stufen in die PV-Module integriert wird. Die hohen Anforderungen an die Zuverlässigkeit der Leistungselektronik sorgen in der Industrie für ein Umdenken. Eine Umfrage [2] zeigte, dass die Industrie gewillt ist, in Bereichen der Wind- und Sonnenenergie mehr für zuverlässigere Systeme zu bezahlen. In der Praxis wird in der Industrie die Zuverlässigkeit allerdings noch größtenteils durch FIT-Raten [3] beschrieben, bei welchen das Ausfallverhalten über die gesamte Produktlebensdauer als konstant angenommen wird. Der Veränderungsprozess hat aber bereits eingesetzt, hin zu einer Analyse der Ausfallursachen auf Basis von physikalischen Ausfallmechanismen [4] und ihrer Einflussparameter. Ziel dieser Betrachtung ist die Ermittlung von Lebensdauermodellen, welche für die relevanten Ausfallmechanismen Änderungen im Ausfallverhalten über die Produktlebensdauer berücksichtigen. Hierfür ist ein strukturiertes Vorgehen, beginnend bei der Systemanalyse und endend bei der Auswertung von Versuchsergebnissen, erforderlich. Dazu erfolgt eine ganzheitliche methodische Zuverlässigkeitsbetrachtung des Gesamtsystems PV-Anlage. Dabei soll der Fokus insbesondere auf dem Herzstück der einzelnen PV-Anlagen-Konzepte – dem Wechselrichter – liegen.

## 2 PV-Anlagen-Konzepte

Eine klassische PV-Anlage besteht aus den PV-Modulen selbst und dem Wechselrichter (WR) [5]. Die einzelnen PV-Module werden der Reihe nach in sogenannten Strings verschaltet und wandeln dabei die von der Sonne auftreffende Solarenergie in einen elektrischen Gleichstrom

um. Der Gleichstrom wird anschließend vom WR in elektrischen Wechselstrom transformiert. Die Regelung der PV-Anlage auf den optimalen Betriebspunkt erfolgt durch den DC/DC-Steller im WR. Dabei passt der DC/DC-Steller die Spannung im Falle einer ungleichmäßigen Leistungsabgabe der einzelnen PV-Module, aufgrund von Verschattungen oder Defekten, an. Somit wird die Einspeisung der maximalen Leistung ins Netz ermöglicht. Neben der Regelung und dem Wechselrichten muss die Elektronik des Wechselrichters im Falle von netzgekoppelten Anlagen auch die netzkonforme Energieeinspeisung gewährleisten.

Die einzelnen Funktionen werden in verschiedenen elektronischen Baugruppen umgesetzt und können je nach PV-Anlagen-Konzept in unterschiedlichen Stufen aus dem Wechselrichter ausgelagert und in das PV-Modul integriert werden. Im Wohnbereich gibt es hierfür vier nennenswerte Konzepte (siehe Bild 1), welche im Folgenden kurz vorgestellt werden [5].

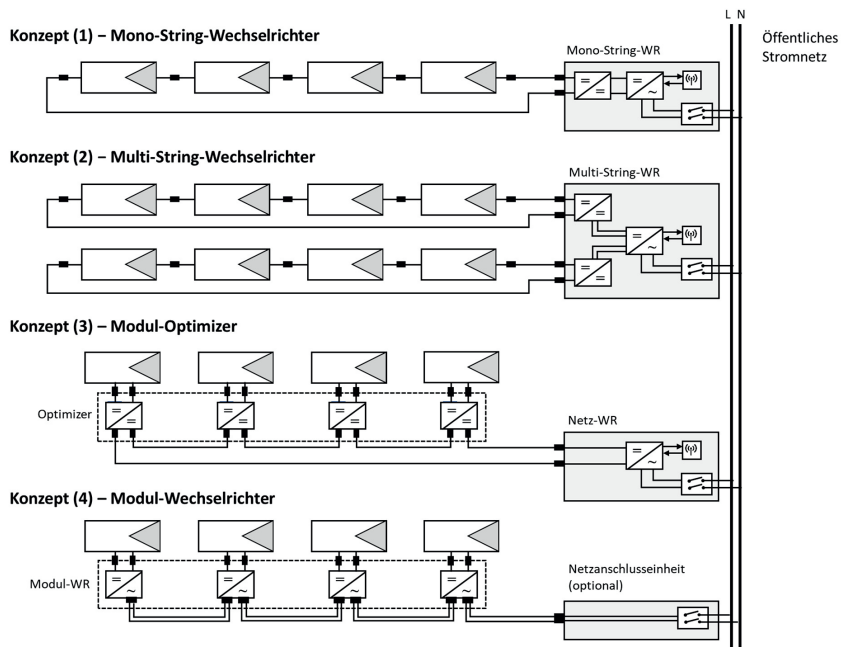


Bild 1: Aufbau unterschiedlicher netzgekoppelter PV-Anlagen-Konzepte

Bei Konzept (1) werden für gewöhnlich alle PV-Module in einem String in Reihe geschaltet und an den Mono-String-Wechselrichter angeschlossen. In diesem befindet sich die gesamte

Elektronik zur Regelung der Anlage, zur Umwandlung des Gleichstroms in Wechselstrom sowie zur Netzeinspeisung. In diesem Konzept besitzt der Wechselrichter einen einzigen DC/DC-Steller. Bei Konzept (2) besitzt der Multistring-Wechselrichter hingegen mehrere DC/DC-Steller, wodurch auch mehrere Strings angeschlossen werden können. Bei Konzept (3) wird der zur Regelung verwendete DC/DC-Steller in das PV-Modul integriert. Diese elektronische Einheit wird als modulintegrierter Optimizer bezeichnet. Die Umwandlung in den Wechselstrom sowie die Netzeinspeisung erfolgt dann über alle PV-Module im anschließenden Netz-Wechselrichter. Bei Konzept (4) besitzt jedes einzelne PV-Modul einen modulintegrierten Wechselrichter. Der Gleichstrom wird hierbei direkt im PV-Modul in einen Wechselstrom gewandelt. Die Leistungen aller Wechselrichter werden einzeln oder optional über eine anschließende Netzanschlusseinheit gebündelt ins Netz eingespeist.

Die Konzepte bieten eine Reihe von unterschiedlichen Vor- und Nachteilen, die an dieser Stelle nicht näher betrachtet werden. Zusätzlich unterliegen die einzelnen elektronischen Komponenten der verschiedenen Topologien unterschiedlichen Belastungen aufgrund variierender Umwelteinflüsse und veränderter Leistungsgrößen.

Im Rahmen dieser Arbeit liegt der Fokus allein auf der Zuverlässigkeitsanalyse der PV-Anlagen-Konzepte. Dies beinhaltet zum einen die Analyse der Auswirkungen eines Komponentenausfalls auf das Gesamtsystem PV-Anlage und zum anderen die Zuverlässigkeitsbewertung unter Berücksichtigung der unterschiedlichen internen und äußeren Belastungen, die mit den unterschiedlichen PV-Konzepten einhergehen. Das hierzu benötigte methodische Vorgehen wird mit Hilfe des nachfolgenden Zuverlässigkeitsprozesses durchgeführt.

### 3 Zuverlässigkeitsprozess

Der Zuverlässigkeitsprozess dient zur Absicherung der Lebensdauer in der Produktauslegung und begleitet den gesamten Produktentstehungsprozess (PEP). Je nach Phase im PEP werden andere Zielsetzungen verfolgt, bei welchen unterschiedliche qualitative und quantitative Methoden zum Einsatz kommen. Mittels qualitativer Methoden können die Schwachstellen bezüglich der kritischen Komponenten und der Komponenten mit kostenintensiven Überdimensionierungen des Systems identifiziert werden. Mit Hilfe der quantitativen Methoden werden Zuverlässigkeitskennwerte berechnet. Die Zuverlässigkeitsabsicherung von Systemen, Baugruppen oder einzelnen Komponenten wird innerhalb eines systematischen und iterativen Vorgehens durchgeführt. Der Prozess hierfür umfasst sieben Arbeitsschritte und ist im Ablaufschema in Bild 2 dargestellt.






Bild 2: Ablaufschema des Zuverlässigkeitsprozesses

In den ersten beiden Arbeitsschritten werden die Zielsetzung und die Systemanforderungen festgelegt. Die Zielsetzung kann sowohl die reine Zuverlässigkeitsabsicherung umfassen als auch beispielsweise eine Designoptimierung auf Grundlage einer zuverlässigkeitsgerechten Auslegung der Komponenten. Damit gibt die Zielsetzung auch gleichzeitig den Detaillierungsgrad und Ablauf des Zuverlässigkeitsprozesses vor.

Um das System zu analysieren müssen sämtliche Einflussgrößen und Randbedingungen ermittelt werden. Im Arbeitsschritt Systemanforderungen erfolgt daher eine ganzheitliche Betrachtung technischer, wirtschaftlicher, ökologischer, gesetzlicher, sowie kunden- und herstellerspezifische Anforderungen aus dem Lasten- und Pflichtenheft.

Anschließend wird in der Systemanalyse (Arbeitsschritt 3) ein Verständnis bezüglich der Systemarchitektur, des Wechselwirkungsverhaltens und der Funktionsweise generiert. Dies kann iterativ auf verschiedenen Detaillierungsebenen des Systems erfolgen, d.h. das System kann ausgehend von der Systemebene immer tiefer bis hin zur Komponentenebene analysiert werden. Die nachfolgenden Arbeitsschritte werden im Hinblick auf die Zielsetzung entsprechend der betrachteten Detaillierungsebene durchgeführt.

Im Rahmen der qualitativen Zuverlässigkeitsanalyse (Arbeitsschritt 4) können die Informationen aus der Systemanalyse genutzt werden, um die Funktionsstruktur des Systems aufzustellen. Anschließend wird das Ausfallverhalten des Systems mittels Fehlerbaumanalyse (FTA) oder Fehlermöglichkeits- und -einflussanalyse (FMEA) untersucht. Unter Berücksichtigung des Wechselwirkungsverhalten werden relevante Ausfallmechanismen und kritische Ereignisse ermittelt. Ein weiterer Aspekt liegt in der Erstellung von Zuverlässigkeitsblockschaltbildern, um die Auswirkungen eines Komponentenausfalls auf das System sowie dessen Redundanzverhalten zu ermitteln.

Die einzelnen Ausfallmechanismen werden im Rahmen einer ABC-Analyse (Arbeitsschritt 5) in Abhängigkeit der vorhandenen Datenlage, der Kritikalität und der Ausfallfolgen für das System klassifiziert. Abhängig von der Klassifizierung wird eine Vorgehensweise vorgegeben, um

Zuverlässigkeitskennwerte zu ermitteln. Bei Bedarf kann hier beispielsweise auf Berechnungen mit Lebensdauermodellen, Versuche oder Simulationen zurückgegriffen werden.

In der quantitativen Zuverlässigkeitsanalyse (Arbeitsschritt 6) werden die Verteilungsparameter für die einzelnen Elemente der Zuverlässigkeitsblockschaltbilder ermittelt. Dieser Schritt kann auf der Ebene von Teilsystemen, bis hin zur Ebene von Komponenten oder Ausfallmechanismen erfolgen. Anschließend wird die Systemzuverlässigkeit entsprechend der Struktur im Zuverlässigkeitsblockschaltbild berechnet [6].

Unter Berücksichtigung aller Systemanforderungen werden alle zuvor ausgearbeiteten Optimierungsmaßnahmen in Arbeitsschritt 7 auf Umsetzbarkeit überprüft. Eine Erweiterung dieses Arbeitsschrittes liegt im Formulieren weiterer Maßnahmen zur Verbesserung der Systemeigenschaften im Hinblick der zuvor definierten Zielsetzungen. Je nach Optimierungsmaßnahme erfolgt ein erneuter Einstieg an den erforderlichen Stellen im Zuverlässigkeitsprozess.

#### **4 Anwendung Zuverlässigkeitsprozess an PV-Anlagen**

Im Folgenden wird der Zuverlässigkeitsprozess zur Analyse vier unterschiedlicher PV-Anlagenkonzepte angewendet. Hierfür wird im 1. Arbeitsschritt zunächst die Zielsetzung festgelegt. Die Grundlage der Zuverlässigkeitsabsicherung der unterschiedlichen PV-Anlagen-Konzepte stellt die Identifikation der kritischen Komponenten des Wechselrichters sowie deren Ausfallfolgen für das Gesamtsystem PV-Anlage dar. Das Ziel ist es also, die kritischen Komponenten des Wechselrichters zu identifizieren und deren Ausfallfolgen für das Gesamtsystem PV-Anlage aufzuzeigen. Zusätzlich müssen Potentiale zur Kosteneinsparung durch Vermeidung von Überdimensionierungen aufgedeckt werden.

Die Systemanforderungen (Arbeitsschritt 2) sind essenziell für die Zuverlässigkeitsabsicherung oder auch Designoptimierung. Da Anlagen von unterschiedlichen Herstellern betrachtet werden, bietet die Aufzählung der Systemanforderungen an dieser Stelle keinen Mehrwert, weshalb darauf verzichtet wird.

Die nachfolgenden Arbeitsschritte werden iterativ auf unterschiedlichen Detaillierungsebenen des Systems durchgeführt. Das System wird dabei ausgehend von der Systemebene immer detaillierter bis hin zur Komponentenebene analysiert.

##### **4.1 Zuverlässigkeitsanalyse der unterschiedlichen PV-Anlagen-Konzepte**

Um zu klären, wie sich ein Ausfall des Wechselrichters auf das Gesamtsystem PV-Anlage auswirkt, wird in Arbeitsschritt 3 zunächst die Systemarchitektur der vier Konzepte bis in die Teilsystemebene aufgestellt. Dabei werden alle Wechselwirkungen zwischen den Teilsystemen und zur Umgebung ermittelt. Hierbei dienen Expertenwissen, Schaltpläne oder auch Kon-

struktionszeichnungen als Informationsquelle. Durch die Verknüpfung der Teilsysteme ergeben sich die Zuverlässigkeitsblockschaltbilder für die gesamte PV-Anlage (s. Bild 3 bis 6). Dabei wird auch die Verkabelung als Steckverbindungen zwischen den Teilsystemen berücksichtigt. Mit Hilfe der Zuverlässigkeitsblockschaltbilder kann eine Aussage über die Auswirkungen eines Ausfalls der einzelnen Teilsysteme auf das Gesamtsystem getroffen werden.




Bild 3: Zuverlässigkeitsblockschaltbild Konzept (1) – Mono-String-Wechselrichter




Bild 4: Zuverlässigkeitsblockschaltbild Konzept (2) – Multi-String-Wechselrichter

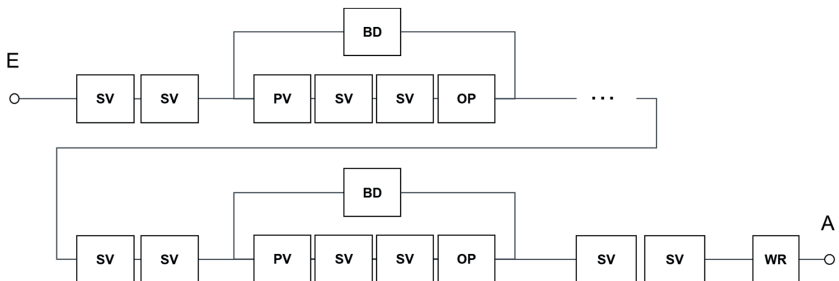


Bild 5: Zuverlässigkeitsblockschaltbild Konzept (3) – Modul-Optimizer

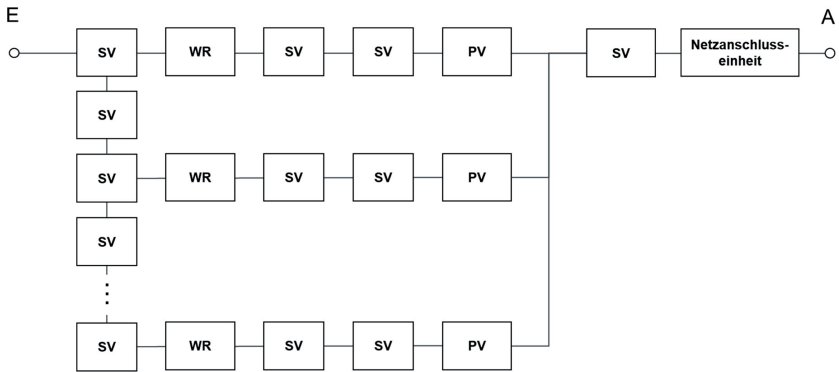


Bild 6: Zuverlässigkeitsblockschaltbild Konzept (4) – Modul-Wechselrichter

In Konzept (1) sind die Komponenten PV-Module („PV“), Steckverbindungen („SV“) und Wechselrichter („WR“) in Reihe geschaltet (s. Bild 3). Ein Ausfall einer einzelnen Komponente führt damit direkt zum Gesamtausfall der PV-Anlage.

In Konzept (2) wird ein zusätzlicher String parallel an den Wechselrichter angeschlossen (s. Bild 4). Der Ausfall einer einzelnen Komponente in diesem String führt zum Ausfall des gesamten Strings. Ein Ausfall des Wechselrichters führt hingegen direkt zum Gesamtausfall der PV-Anlage.

In Konzept (3) besitzt jedes PV-Modul einen eigenen Optimizer (OP), siehe Bild 5. Fällt dieser, das PV-Modul oder die Steckverbindungen dazwischen aus, wird nur durch das jeweilige PV-Modul keine Leistung mehr eingespeist. In diesem Fall springt eine Bypass-Diode (BD) ein, welche die Funktionsfähigkeit der gesamten PV-Anlage sicherstellt. Erst ein zusätzlicher Ausfall der BD führt zu einem Ausfall der gesamten PV-Anlage. Sowohl der Ausfall der Steckverbindungen zwischen den Optimizern als auch der Ausfall des Wechselrichters führt unmittelbar zum Gesamtausfall der PV-Anlage.

In Konzept (4) wird ein Modul-WR in jedes PV-Modul integriert (s. Bild 4). Fällt dieser, das PV-Modul oder die Steckverbindungen dazwischen aus, entfällt auch hier nur die Leistung eines PV-Moduls. Je nach Bauart der Steckverbindung am Wechselrichter führt ein Ausfall zum Ausfall eines einzelnen PV-Moduls, mehrerer PV-Module oder zum Gesamtausfall der PV-Anlage.

Der Ausfall eines Wechselrichters wirkt sich also unterschiedlich auf die einzelnen Konzepte aus. In den Konzepten (1), (2) und (3) ist der WR das zentrale Element der PV-Anlage. Der

Ausfall führt damit direkt zum Gesamtausfall der Anlage. Aus diesem Grund sind hohe Zuverlässigkeitsanforderungen für den Wechselrichter erforderlich. In Konzept (4) führt der Ausfall des Modul-Wechselrichters hingegen nur zum Wegfall des jeweiligen PV-Moduls. Hier ist die Folge also nicht ein Gesamtausfall der PV-Anlage, sondern nur eine Leistungsminderung eines einzelnen PV-Moduls im gesamten System.

Das Teilsystem WR weist außerdem unterschiedliche Systemarchitekturen für die jeweiligen Anlagen-Konzepte auf. Während der Wechselrichter der Konzepte (1), (2) und (4) weitgehend aus einem DC/DC-Steller und einer Wechselrichtungseinheit besteht, besitzt der Wechselrichter des Konzepts (3) keinen DC/DC-Steller und ist damit schlanker aufgebaut. Der Modul-WR des Konzepts (4) ist zudem im Vergleich zu den anderen deutlich kleiner dimensioniert, da dieser nur noch für die Leistung eines einzelnen PV-Moduls ausgelegt ist. Damit weichen seine internen Belastungen, verursacht durch Strom und Spannung, von den anderen Konzepten ab. Hinzu kommt hierbei noch die abweichende äußere Belastung des Modul-Wechselrichters, da er durch die PV-Modulintegration den äußeren Umweltbelastungen direkt ausgesetzt ist.

Systemarchitektur, Komponentenanzahl und Belastungen der einzelnen Wechselrichter hängen stark mit dem Anlagenkonzept zusammen. Die Anzahl der elektronischen Bauteile hat nach [7] einen großen Einfluss auf die Zuverlässigkeit. Um die einzelnen PV-Anlagen-Konzepte zuverlässigkeitstechnisch abzusichern, wird der Zuverlässigkeitsprozess im Folgenden auf der Ebene des Wechselrichters weitergeführt. Das Ziel ist es hierbei die kritischen Komponenten des Wechselrichters zu identifizieren und Potentiale zur Kosteneinsparung durch Vermeidung von Überdimensionierungen aufzudecken.

## 4.2 Zuverlässigkeitsanalyse des Wechselrichters

Im Folgenden wird beispielhaft ein Mono-String-Wechselrichter in der Leistungsklasse bis 5 kW betrachtet. Neben der Absicherung der Hauptfunktionen des Wechselrichters, werden in (Arbeitsschritt 1 & 2), die bereits zu Beginn in Kapitel 4 erläuterten Zielsetzungen berücksichtigt. Ziel der weiteren Schritte ist es, kritische Baugruppen zu identifizieren und für deren Komponenten Versuche zu planen, um Lebensdauermodelle abzuleiten und zu parametrieren. Dazu wird eine Systemanalyse (Arbeitsschritt 3) durchgeführt, bei der alle externen Einflussparameter auf das System Wechselrichter festgehalten werden, siehe Bild 7.

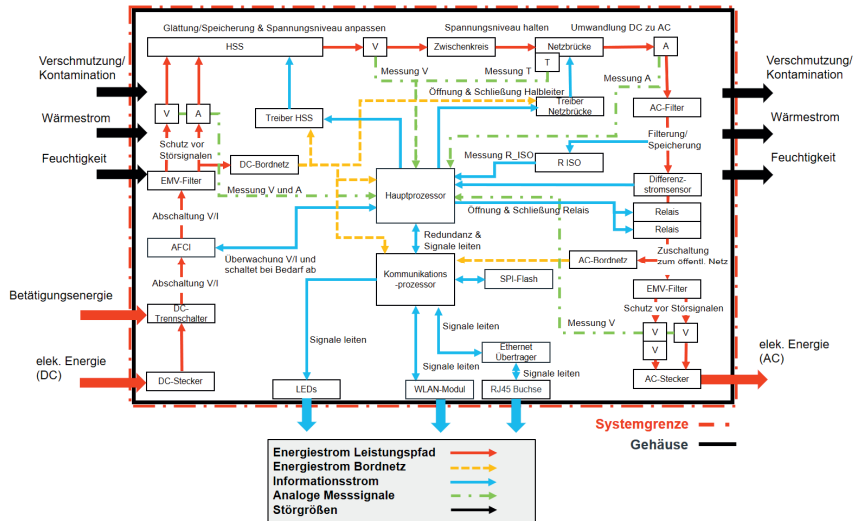
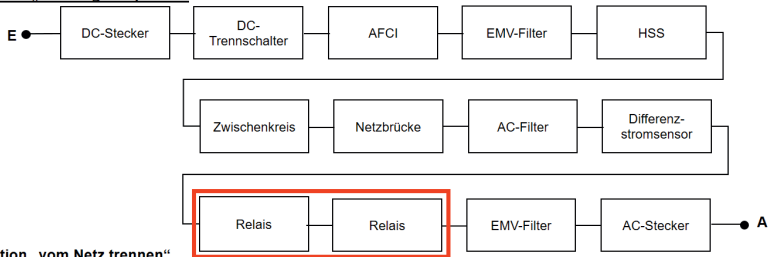


Bild 7: Systemarchitektur Wechselrichter mit internen und externen Wechselwirkungen

Neben den äußeren Wechselwirkungen werden im nächsten Schritt der interne Aufbau des Wechselrichters, sowie die internen Wechselwirkungen betrachtet. Aus der definierten Zielsetzung für den Zuverlässigkeitsprozess geht hervor, wie tief das System analysiert wird. In einigen Anwendungsszenarien ist es sinnvoll, nur bis zur Baugruppenebene vorzudringen, um zum Beispiel verschiedene Topologien vergleichen zu können. Die unterschiedlichen Wechselwirkungsparameter im System Wechselrichter werden in Abhängigkeit der funktionalen Zusammenhänge in Kategorien [8] eingeteilt. Für ein besseres Verständnis werden diese noch weiter unterteilt: Energiestrom Leistungspfad, Energiestrom Bordnetz, Informationsstrom, analoge Messsignale und Störgrößen. Zusätzlich zu den funktionsbezogenen Wechselwirkungen, werden auch die restlichen physikalischen Wechselwirkungen zwischen den Baugruppen betrachtet. Ein Beispiel dafür ist die starke Eigenerwärmung der Netzbrücke und des AC-Filters. Diese führt durch Wärmeleitung zu Temperaturerhöhungen an den umliegenden Baugruppen. Qualitativen Maßnahmen (Arbeitsschritt 4), wie eine räumliche Auslagerung, Erhöhung von Abständen auf der Leiterplatte und dem gezielten Lenken von kühler Luft zur Konvektion, werden hierfür eingesetzt. Weitere, in der Leistungselektronik häufig auftretende physikalische Wechselwirkungen sind Elektromagnetismus, Wärmestrahlung und Vibrationen. Aus dem in der Systemanalyse generierten Wissen zu den funktionalen Zusammenhängen des Wechsel-

richters, werden Zuverlässigkeitsblattschaltbilder [8] erstellt. Anhand dieser lässt sich die Absicherung der Systemzuverlässigkeit berechnen. Um für das System Wechselrichter die richtigen Zuverlässigkeitsblattschaltbilder zu bestimmen, ist es wichtig, dabei die abzusichernde Funktion zu beachten. Im Rahmen dieses Beitrags werden die Zuverlässigkeitsblattschaltbilder für zwei Hauptfunktionen betrachtet, siehe Bild 8. Erstens, die Grundfunktion Leistung einspeisen, welche für die wirtschaftliche Nutzung des Wechselrichters essenziell wichtig ist. Zweitens, die Sicherheitsfunktionen, um zum Schutz von Menschen und Umgebung über den DC-Trennschalter die Solarzellen-Strings vom Wechselrichter zu trennen und ebenso die Einspeisung in das AC-Stromnetz über die AC-Relais zu trennen. Beim Vergleich dieser beiden Funktionen fällt ein gravierender Unterschied in den Zuverlässigkeitsblattschaltbildern auf. Die AC-Relais sind dabei je nach Funktion einmal in Reihe und einmal parallelgeschaltet, da es für die Sicherheitsfunktion ausreicht ein AC-Relais zu öffnen. Deshalb ist das AC-Relais, nur bei der Betrachtung der Funktion „Leistung einspeisen“ als kritisch einzuordnen.

#### Funktion „Leistung einspeisen“



#### Funktion „vom Netz trennen“




Bild 8: Zuverlässigkeitstechnisch abzusichernde Funktionen des Systems Wechselrichter

Auf Basis der Systemanalyse werden die verschiedenen Baugruppen kategorisiert (Arbeitsschritt 5), um das weitere Vorgehen differenzieren zu können. Die Baugruppen des Wechselrichters werden nach der ABC-Methode [8] eingeteilt. Baugruppen, welche unkritisch sind werden auf Baugruppenebene als C-Teile (risikoneutral) eingeordnet. Aufgrund sehr hoher Zuverlässigkeit werden diese Baugruppen in der weiteren Betrachtung mit der Systemzuverlässigkeit von  $R = 1$  bewertet. Überdimensionierte und im Feld unauffällige Baugruppen, welche hohe Kosten verursachen, werden unter Betrachtung des Zuverlässigkeitsziels „Reduzierung

von „Überdimensionierung“ auch als A- oder B-Teil eingeordnet. Die restlichen Baugruppen für die Kategorien A (risikoreich) und B (risikoreich) unterscheiden sich bei der Kategorisierung darin, ob zu den Komponenten der Baugruppen ein Lebensdauermodell zur Auswertung einer Betriebsfestigkeitsanalyse mit Lastkollektiven vorliegt (A-Teil) oder nicht (B-Teil). Aus Kosten- und Zeitgründen ist die Anzahl der durchführbaren Versuche begrenzt. Deshalb werden die Baugruppen unter Berücksichtigung der aufgestellten Ziele priorisiert. In diesem Beispiel werden die Sicherheitsrelevanz, die Schädigung umliegender Komponenten, die aktuelle Felderfahrung, die Reduzierung von Überdimensionierung und starke Eigenerwärmung als Kriterien berücksichtigt. Die mit Expertenwissen erarbeitete Prioritätenliste der Baugruppen ist in Tabelle 1 dargestellt.

Tabelle 1: Einteilung und Priorisierung der Baugruppen

Baugruppe	ABC-Analyse	Priorisierung für Versuche anhand Zuverlässigkeitszielen für B-Teile				Priorliste	
	B-Teile (risikoreich)	Sicherheits- relevant	Schädigung umliegender Komponenten	kritisch aus Felderfahrung	Überdimensio- nierung reduzieren	Eigenerwärmung (diss. Energie)	
DC-Trennschalter	X	X		X	X		1
EMV-Filter (DC & AC Seite)	X		X				2
Stromsensor	X						3
HSS	X		X	X	X	X	1
DC-Bordnetz	X		X				2
AC-Filter	X		X		X	X	1
Relais	X	X		X	X		1

Aus der Prioritätenliste der Baugruppenkategorisierung geht hervor, dass neben dem DC-Trennschalter und den AC-Relais, welche für die Sicherheitsfunktion kritisch sind, Komponenten wie der AC-Filter und dem Hochsetzsteller (HSS) in Versuchen betrachtet werden müssen. Der HSS ist dabei ein DC/DC-Steller, welcher für den Einsatz im Mono-String-Wechselrichter die Aufgabe hat, die angelegte DC-Spannung auf ein konstantes Niveau zu heben. Zur Analyse der Baugruppenzuverlässigkeit wird nun der AC-Filter weiter betrachtet, welcher aus den Komponenten AC-Drossel und AC-Folienkondensator besteht. Für Versuche und die Entwicklung eines Lebensdauermodells werden die Folienkondensatoren ausgewählt, die neben dem AC-Filter und der HSS auch in einigen anderen Baugruppen des Wechselrichters AC- und DC-seitig Verwendung finden. Aufgrund großer Stückzahl und beachtlichen Anschaffungskosten, ist hier eine Reduzierung von Überdimensionierung durch belastbare Lebensdauermodelle vorteilhaft. Dies wird durch ein parametrisiertes Lebensdauermodell bewerkstelligt.

Da ein Lebensdauermodell nur für einen Alterungsmechanismus gültig ist, wird für die Folienkondensatoren zur Planung von Lebensdauerversuchen eine Fehlerbaumanalyse [8] durchgeführt. Dazu werden die verschiedenen Ausfallarten und die zugrundeliegenden Ausfallmechanismen bis zu den physikalischen Einflussparametern bestimmt. Für die Berechnung eines



Lebensdauermodells ist es wichtig, den Alterungsvorgang zu quantifizieren, weshalb in Bild 9 zwischen beobachtbaren und spontan auftretenden Ausfallarten unterschieden wird.




Bild 9: Fehlerbaumanalyse (Teil 1) zur Bestimmung der Ausfallmechanismen und deren Einflussparameter für Zuverlässigkeitsversuche am Beispiel Folienkondensator

Eine beobachtbare Ausfallart stellt dabei die Überschreitung der C-Abbau Grenze dar. Dies entspricht einer Reduktion der Kapazität auf einen definierten relativen Wert, welcher in der Industrie als EOL Kriterium verwendet wird. Die C-Abbau Grenze wird in Bild 10 weiter im Fehlerbaum betrachtet.

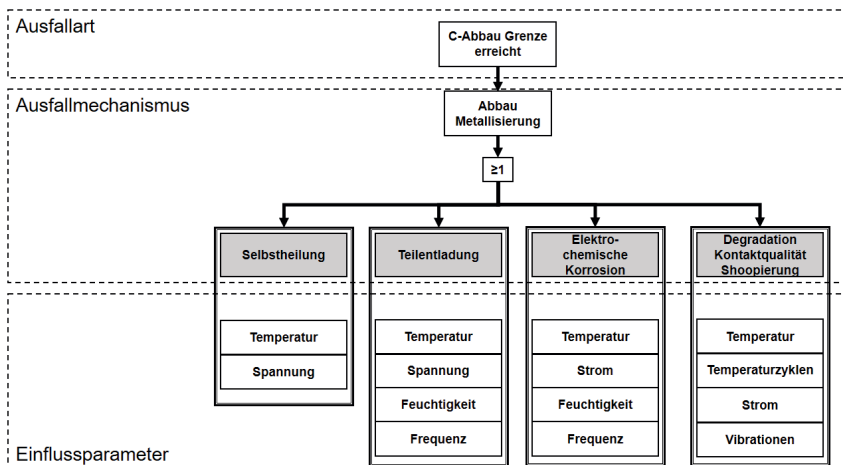


Bild 10: Fehlerbaumanalyse (Teil 2) zur Bestimmung der Ausfallmechanismen und deren Einflussparameter für Zuverlässigkeitsversuche am Beispiel Folienkondensator

Zum C-Abbau tragen dabei hauptsächlich die vier Ausfallmechanismen Selbstheilung, Teilentladung, elektrochemische Korrosion und Kontaktierungsverlust bei. Die Selbstheilung [9] stellt dabei ein Ausheilen von Kurzschlüssen zwischen Folienlagen im Kondensator dar, indem

die umliegende Metallisierung verdampft wird. Bei der Teilentladung [9] kommt es durch hohe Feldstärken zum Zünden lokaler Entladungen, welche zu parasitären Strömen oder im Extremfall zu einem Kurzschluss führen, und Folie und Metallisierung beschädigen. Zu beachten gilt es hier, dass die verschiedenen Ausfallmechanismen abhängig von der Spannungsart AC oder DC unterschiedlich stark ausgeprägt auftreten. Für AC-Folienkondensatoren wurden dabei die Ausfallmechanismen Teilentladung und elektrochemische Korrosion, als kritisch identifiziert. Für DC-Folienkondensatoren sind die relevanten Ausfallmechanismen für C-Abbau dagegen der Selbstheilungsprozess und die elektrochemische Korrosion.

## 5 Fazit und Ausblick

Die Anwendung des vorgestellten Zuverlässigkeitsprozesses ermöglicht es erstmals, neben der Absicherung von Systemen und Komponenten, ebenso aktiv weitere Ziele aus dem Produktentstehungsprozess (PEP) wie dem Reduzieren von Überdimensionierung von Beginn an zu betrachten. Ein qualitativer Vergleich unterschiedlicher PV-Anlagen-Konzepte auf Systemebene wurde durchgeführt und der Wechselrichter als kritisches Teilsystem identifiziert. Dazu wird am Beispiel des Mono-String-Wechselrichters eine Analyse bis zu den einzelnen Baugruppen und Komponenten durchgeführt. Durch die Anwendung des Zuverlässigkeitsprozesses wird sichergestellt, dass keine Systemelemente, interne oder externe Wechselwirkungen sowie keine Ausfallmechanismen unberücksichtigt bleiben. Zur Absicherung sind parametrisierte Lebensdauermodelle für die einzelnen Ausfallmechanismen erforderlich, um Raffungsfaktoren zu identifizieren. Zur optimalen Planung von Versuchen für die Erstellung von Lebensdauermodellen müssen mindestens zwei Lastniveaus für jeden Einflussparameter definiert werden. Diese müssen neben den Faktoren Zeit und Kosten, auch eine möglichst genaue Parametrierung des Lebensdauermodells gestatten, um eine Extrapolation auf Feldniveau mit einer hohen Aussagewahrscheinlichkeit zu ermöglichen. Dazu müssen die Ausfallmechanismen Teilentladung und elektrochemische Korrosion bei AC-Folienkondensatoren getrennt betrachtet werden. Erschwert wird dies, da beide Ausfallmechanismen auch bei ihren Einflussparametern Überschneidungen aufweisen. Daher werden im nächsten Schritt Vorversuche durchgeführt, um die Parameterräume für die Versuchsplanung der Lebensdauermodellermittlung festzulegen.

Die Forschungsergebnisse wurden im Rahmen der vom BMWI geförderten Projekte 03EE1057G und 03EE1054B erarbeitet. Vielen Dank an dieser Stelle an die beteiligten Projektpartner für Ihre Expertise und gute Zusammenarbeit.

Gefördert durch:



Bundesministerium  
für Wirtschaft  
und Energie

## Literaturquellen

- [1] Presse- und Informationsamt der Bundesregierung, Mittwoch, 17. Februar 2021, Erneuerbare Energien - Ein neues Zeitalter hat begonnen, <https://www.bundesregierung.de/breg-de/themen/energiewende/energie-erzeugen/erneuerbare-energien-317608>, letzter Zugriff am 25.02.2021
- [2] J. Falck, C. Felgемacher, A. Rojko, M. Liserre and P. Zacharias, "Reliability of Power Electronic Systems: An Industry Perspective", in IEEE Industrial Electronics Magazine, vol. 12, no. 2, pp. 24-35, 2018.
- [3] D. Roy, Abeera et al.; Performance and Reliability Analysis of 13-Level Asymmetrical Inverter with Reduced Devices; Springer Nature Singapore Pte Ltd.; 2020
- [4] H. Wang, M. Liserre, F. Blaabjerg, P. de Place Rimmen, J.B. Jacobson, T. Kvisgaard, J. Landkildehus, "Transitioning to Physics-of-Failure as a Reliability Driver in Power Electronics" in IEEE Journal of emerging and selected topics in power electronics, Vol. 2, No. 1, 2014
- [5] Prof. Dr.-Ing. K. Mertens, Photovoltaik – Lehrbuch zu Grundlagen, Technologie und Praxis, Carl Hanser Verlag, 2020
- [6] A. Grundler, M. Dazer, B. Bertsche, "Reliability-Test Planning Considering Multiple Failure Mechanisms and System Levels", Proc. RAMS 2020 Conference, 2020
- [7] Assoc. Prof. W. Franke, The Impact of Optimizers for PV-Modules, University of Southern Denmark, 2019
- [8] B. Bertsche, P. Göhner, U. Jensen, W. Schinköthe, H. Wunderlich, "Zuverlässigkeit mechatronischer Systeme", Springer Verlag, 2009
- [9] H.M. Umran et al., "Ageing: Causes and Effects on the Reliability of Polypropylene Film used for HVDC Capacitor", IEEE Access, 2020



# Konzeption und Vergleich einer Methode zur Berechnung der Zuverlässigkeit bei variabler Belastung auf Basis einer probabilistischen Schädigungsakkumulation

Prof. Dr.-Ing. **Peter Zeiler**, Fakultät Maschinen und Systeme,  
Hochschule Esslingen, Göppingen

## Kurzfassung

Die Zuverlässigkeit, die ein Produkt im Betrieb erreicht, hängt maßgeblich von der Belastung ab, die es erfährt. Bei einer variablen Betriebsbelastung muss der Einfluss der variierenden Belastung bei der Berechnung der Zuverlässigkeit berücksichtigt werden. Hierfür stehen unterschiedliche Methoden zur Verfügung, u.a. die Methoden nach Dubi, Mettas, Palmgren-Minner, Rathod et al. und Zhu et al., die sowohl aus dem Fachgebiet der Zuverlässigkeitstechnik stammen, als auch aus der Betriebsfestigkeitsberechnung.

Diese Methoden lassen sich für die Prognose der Zuverlässigkeit bzw. der Lebensdauer bei Betriebsbelastung und damit für einen rechnerischen Zuverlässigkeits- bzw. Lebensdauernachweis auf Basis eines Lebensdauermodells einsetzen. Die Methoden unterscheiden sich dabei in ihren Modellannahmen deutlich.

In diesem Beitrag wird eine neue Methode konzipiert, die Elemente aus Methoden der Betriebsfestigkeit als auch der Zuverlässigkeitstechnik enthält. Die neue Methode vereint zentrale Annahmen und Eigenschaften dieser Methoden. In dieser Methode wird der Schädigungsprozess als stochastischer Vorgang angenommen. Die konzipierte Methode ermöglicht die Berechnung der zeitabhängigen Zuverlässigkeit bei variabler Belastung auf der Basis einer probabilistischen Schädigungsakkumulation.

## 1. Einleitung

Die Belastung, die auf ein Produkt im Betrieb wirkt, bestimmt maßgeblich dessen Lebensdauer und Zuverlässigkeit. Es können unterschiedliche Arten einer Betriebsbelastung vorhanden sein. Die Belastung kann über der Zeit konstant sein oder variieren. Eine konstante Belastung wird auch als einstufig bezeichnet, besteht also aus einer Stufe mit konstantem Lastniveau. Bei zwei und mehr Laststufen spricht man von einer mehrstufigen Belastung, d.h. jede Stufe besitzt ein bestimmtes Lastniveau. Eine variierende bzw. variable Belastung kann u.a. vorliegen als stufenförmige, rampenförmige, zyklische oder stochastisch über der Zeit variierende Belastung [1].

Bei einer variablen Betriebsbelastung muss der Einfluss der variierenden Belastung bei der Berechnung der Zuverlässigkeit berücksichtigt werden. Hierfür stehen unterschiedliche Methoden zur Verfügung. Diese lassen sich dem Fachgebiet der Zuverlässigkeitstechnik, als auch aus der Betriebsfestigkeitsberechnung zuordnen.

Diese Methoden lassen sich für die Prognose der Zuverlässigkeit bei Betriebsbelastung und damit für einen rechnerischen Zuverlässigkeits- bzw. Lebensdauernachweis auf Basis eines Lebensdauer-Last-Modells einsetzen. Das Lebensdauermodell kann sowohl experimentell, beispielsweise durch beschleunigte Erprobung [1], [2], oder Wöhlerversuche [3], als auch synthetisch bestimmt werden.

In diesem Beitrag wird eine neue Methode konzipiert, die Elemente der Schädigungs- und der Zuverlässigkeitsberechnung enthält, und mit bekannten Methoden verglichen. Der Beitrag ist wie folgt aufgebaut: Zunächst werden die bekannten Methoden kurz vorgestellt. Danach wird das Konzept der neuen Methode vorgestellt. Es erfolgt ein Vergleich der Methoden anhand qualitativer Merkmale und getroffener Modellannahmen.

## **2. Methoden zur Lebensdauer- bzw. Zuverlässigkeitsberechnung bei variabler Belastung**

In diesem Kapitel werden mehrere Methoden vorgestellt, die für die Lebensdauer- bzw. Zuverlässigkeitsberechnung bei variabler Belastung anwendbar sind. Sie stammen sowohl aus dem Fachgebiet der Zuverlässigkeitstechnik als auch aus der Betriebsfestigkeitsberechnung. Die Vorstellung erfolgt hierbei stark zusammengefasst. Eine ausführlichere Beschreibung der Methoden findet sich in den angegebenen Literaturquellen. Einige wesentliche Aspekte der jeweiligen Methoden werden im Vergleich in Kapitel 4 beleuchtet.

### **Methode nach Dubi**

Dubi beschreibt in [4] eine Methode, die die erreichte Alterung als Übergangsbedingung bei einem Lastsprung von einem Lastniveau auf ein anderes Niveau verwendet. Als Alterung wird die erreichte Ausfallwahrscheinlichkeit im bisherigen Lastniveau verwendet, um eine bedingte Ausfallwahrscheinlichkeitsverteilung für das folgende Lastniveau zu erzeugen. Mit dieser Methode lässt sich in Kombination mit einer Monte-Carlo-Simulation der zeitabhängige Verlauf der Zuverlässigkeit bei einer mehrstufigen Betriebsbelastung berechnen [5].

### **Methode nach Mettas**

Mettas stellt in [6] eine Methode vor, die auf dem Cumulative Exposure Modell (CEM) nach Nelson [1] basiert und die Zuverlässigkeitsberechnung bei variabler Betriebslast ermöglicht.

Die Betriebslast kann sowohl ein Mehrstufenprofil sein als auch ein beliebiges zeitabhängiges Lastprofil. In die Berechnung der Zuverlässigkeit fließt hierbei ein probabilistisches Lebensdauer-Last-Modell ein. Das Ergebnis ist ein zeitabhängiger Verlauf der Zuverlässigkeit unter Betriebsbedingung, wie er beispielsweise auch in [7] berechnet wird.

### **Methode nach Palmgren-Miner**

Die lineare Schädigungsakkumulation nach der Palmgren-Miner-Hypothese geht von einem linearen, monotonen und stetigen Anstieg einer Schädigung aus [8], [9]. Als Lebensdauermodell wird meistens eine Wöhlerlinie genutzt, welche die Last-Lebensdauer-Beziehung für eine spezifische Überlebenswahrscheinlichkeit beschreibt [3]. Die Betriebslast kann als Mehrstufen-Profil in Form eines Lastkollektivs vorliegen. Die Anwendung der Palmgren-Miner-Hypothese liefert eine akkumulierte Schädigung über alle Lastniveaus. Bei einer theoretische Schädigungsgrenze ergibt sich ein Lebensdauerwert bzw. eine -linie, bei der die gleiche Überlebenswahrscheinlichkeit vorliegt, die für die Wöhlerlinie gilt.

Für diese in der Praxis sehr häufig angewandte Methode zum rechnerischer Nachweis einer Betriebsfestigkeit existieren unterschiedliche Erweiterungen, beispielsweise für die Annahme eines nichtlinearen Anstiegs der Schädigung (z.B. [10] und [11]).

### **Methode nach Rathod et al.**

Rathod et al. entwickeln in [12] eine Methode zur probabilistischen Modellierung der Schädigungsakkumulation für mehrstufige Betriebsbelastungen. Hierbei verwenden sie die Palmgren-Miner Hypothese, d.h. es wird eine lineare Schädigungsakkumulation angenommen. Rathod et al. beschreiben die Schädigungsakkumulation als nicht-stationären Gaußprozess und nehmen eine normalverteilte Schädigung an. Auf Basis der erreichten Schädigungsverteilung und einer ebenfalls als normalverteilt angenommenen ertragbaren Schädigung wird die Zuverlässigkeit als Funktion über der Zeit berechnet.

### **Methode nach Zhu et al.**

Zhu et al. erweitern in [13] die Methode nach Rathod für eine bestimmte Variante der nichtlinearen Schädigungsakkumulation. Die grundlegenden Merkmale der Methode nach Rathod et al. werden hierbei beibehalten. Zhu et al. nehmen eine lognormalverteilte Schädigung an.

### 3. Konzeption einer Methode zur Berechnung der zeitabhängigen Zuverlässigkeit bei variabler Belastung auf Basis einer probabilistischen Schädigungsakkumulation

Im Folgenden wird die Konzeption einer neuen Methode vorgestellt, die die Berechnung der zeitabhängigen Zuverlässigkeit bei variabler Belastung auf Basis einer probabilistischen Schädigungsakkumulation ermöglicht. Es werden die wesentlichen Elemente dieser Konzeption beschrieben, diese umfassen

- die Beschreibung der Schädigung als stochastischer Vorgang,
- die Definition eines Ausfallkriteriums,
- die Ermittlung der Schädigungsverteilung in einem Lastniveau,
- den Schädigungsanstieg bei konstantem Lastniveau,
- den Lastsprung zwischen zwei konstanten Lastniveaus sowie
- die Ermittlung einer zeitabhängigen Funktion der Ausfallwahrscheinlichkeit bzw. der Zuverlässigkeit.

Als Grundlage für die Berechnung wird ein probabilistisches Lebensdauer-Last-Modell (LM) angenommen [2]. Ein solches Modell beschreibt die stochastische Lebensdauer  $\tau_{LM}(s)$  als Funktion einer Belastungsvariablen  $s$ , in manchen Fällen auch als Funktion mehrerer Belastungsvariablen. Es wird angenommen, dass sich das Modell über der Zeit nicht ändert, d.h. es bleibt über alle Laststufen bzw. -verläufe hinweg unverändert. Ferner wird im Modell angenommen, dass das Belastungsniveau über der Zeit konstant bleibt. Das probabilistische Lebensdauer-Last-Modell für sich ist also nicht in der Lage, eine variable Belastung zu berücksichtigen. Daher sind die im Folgenden beschriebenen Elemente der entwickelten Methodenkonzeption erforderlich.

Die Schädigung in einem Bauteil, die einem Ausfall vorausgeht, wird als nicht messbar angenommen und der Zuwachs über eine Hypothese beschrieben, z.B. durch die lineare Schädigungsakkumulation nach Palmgren-Miner oder durch eine andere nichtlineare Hypothese. Je nach gewählter Hypothese erfolgt der Zuwachs der Schädigung aufgrund einer vorliegenden Belastung linear oder nichtlinear. Erreicht die vorhandene Schädigung eine bestimmte ertragbare Schädigung, dann erfolgt ein Ausfall. In einem Ermüdungstest würde damit bei Erreichen dieses Ausfallkriteriums die Auswirkung einer Schädigung in einem Bauteil in Form einer Ausfallzeit messbar.



## Schädigung als stochastischer Vorgang

Die erreichte Schädigung eines Bauteils wird als stochastische Größe angenommen und die weitere Zunahme dieser Schädigung als nichtstationärer stochastischer Prozess. Eine Zunahme der Schädigung erfolgt, wenn eine Belastung vorliegt. Variierende Belastungen führen zu einer kumulierenden Schädigung. Es wird angenommen, dass die Schädigung nicht reversibel ist und keine Selbstheilung erfolgt. Daraus ergibt sich eine monoton steigende Schädigung. Darüber hinaus ist der Verlauf der Schädigung stetig, d.h. er besitzt keine sprunghaften Veränderungen.

Die in einem Bauteil zu einem Zeitpunkt  $t$  erreichte Schädigung wird durch eine nichtnegative reelle Größe  $d$  beschrieben. Im einzuführenden Modell der neuen Methode wird diese als Zufallsgröße  $\delta$  aufgefasst. Dabei ist  $\delta$  eine nicht-negative, stetige Zufallsgröße, deren zeitliche Veränderung durch einen nichtstationären stochastischen Prozess  $\delta(t)$  beschrieben wird. Dieser Prozess wird in den folgenden Abschnitten weiter erläutert. Die Schädigung zum Zeitpunkt  $t$  wird über eine Verteilungsfunktion  $F_\delta(d, t)$  oder eine entsprechende Dichtefunktion  $f_\delta(d, t)$  beschrieben, wie in Bild 1 unten dargestellt ist. Die vorgestellte Methode geht von einem stetigen, monotonen Anstieg der Schädigung bis zu einer Ausfallgrenze aus. Dies gilt für alle Quantile  $d_q(t) = F_\delta(t)^{-1}(q)$ ,  $0 < q < 1$ , der Schädigungsverteilung  $F_\delta(d, t)$ , auch über Lastsprünge hinweg. Der Anstieg der Schädigung innerhalb einer Laststufe kann je nach angenommener Hypothese linear oder nichtlinear erfolgen.

## Ermittlung der Schädigungsverteilung in einem konstanten Lastniveau

Die Verteilung und der Anstieg der erreichten Schädigung  $\delta(t)$  in einer Laststufe, d.h. bei einem konstanten Lastniveau  $s$  über der Zeit, ergibt sich direkt aus der Verteilungsfunktion  $F_{\tau, LM}(t, s)$  der Laststufe auf Basis des angenommenen probabilistischen Lebensdauer-Last-Modells, der Initial-Schädigung  $\delta_0(t')$  und der gewählten Schädigungshypothese.

Hierbei wird folgendes angenommen:

Ausgehend von einer Initialschädigung  $\delta_0(t')$  steigt die Schädigung  $\delta(t)$ ,  $t > t'$ , in Abhängigkeit der gewählten Schädigungshypothese an, bis sie eine Grenzschrädigung  $\delta_c(t)$  erreicht. Die Initialschädigung und die Grenzschrädigung können hierbei als deterministischer Wert oder als Zufallsgröße aufgefasst werden. Werden sie als Zufallsgrößen betrachtet, dann wird die Initialschädigung durch die Schädigungsverteilung  $F_{\delta_0}(d, t')$  beschrieben und die Grenzschrädigung durch  $F_{\delta_c}(d, t)$ . Der Anstieg erfolgt für alle Quantile  $d_q(t)$ ,  $0 < q < 1$ , der Schädigungsverteilung  $F_\delta(d, t)$  in Abhängigkeit der gewählten Schädigungshypothese bis sie bei Erreichen

der Grenzschädigung  $\delta_c(t)$  die Quantile der Verteilungsfunktion  $F_\tau(t)$  der Ausfallzeit als Zeitwerte ergeben, was in den folgenden Abschnitten noch näher erläutert wird.

### Definition eines Ausfallkriteriums

Die Schädigungsgrenze  $\delta_c(t)$  wird im vorgestellten Modell als deterministischer Wert oder als eine Zufallsgröße aufgefasst. Überschreitet der stochastische Prozess  $\delta(t)$  erstmalig diese Schädigungsgrenze, dann ergibt sich hierbei die zufällige Zeit des Ausfalls als kleinstes nicht-negatives  $t$ , für das  $\delta(t) \geq \delta_c(t)$  gilt, d.h.  $\tau = \inf\{t \geq 0 : \delta(t) \geq \delta_c(t)\}$ . Das auf diese Weise definierte  $\tau$  ist also ebenfalls eine Zufallsgröße.

Bei einer deterministischen Schädigungsgrenze ergeben sich für alle Quantile  $d_q$  der Schädigungsverteilung  $F_\delta(d, t)$ ,  $0 < q < 1$ , die Quantile  $t_{\tau, q} = F_\tau^{-1}(q)$ ,  $0 < q < 1$ , der Verteilungsfunktion des zufälligen Ausfallzeitpunkts  $\tau$  über den Zusammenhang  $d_q(t_{\tau, 1-q}) = d_c(t_{\tau, 1-q})$ ,  $0 < q < 1$ . Ist die Schädigungsgrenze eine Zufallsgröße, dann kann in Analogie zu den Methoden nach Rathod et al. und Zhu et al. eine Interferenz zwischen Schädigungsverteilung  $F_\delta(d, t)$  und Grenzschädigungsverteilung  $F_{\delta_c}(d, t)$  gebildet werden.

### Berücksichtigung eines konstanten Lastniveaus beim Schädigungsanstieg

Basierend auf den vorherigen Annahmen kann für jede konstante Belastung  $s$ ,  $s > 0$ , mittels eines probabilistischen Lebensdauer-Last-Modells  $F_{\tau, LM}(t, s)$ , bei angenommener Verteilung der Initial-Schädigung für jedes Quantil der Schädigungsverteilung der Anstieg über der Zeit bestimmt werden. Hierbei ist  $F_{\tau, LM}(t, s)$  die Verteilungsfunktion der Lebensdauer für eine gegebene konstante Belastung.

Für den speziellen Fall, dass die konstante Belastung  $s$  von Beginn an vorliegt, ergibt sich Folgendes: Zum Zeitpunkt  $t = 0$  liegt keine Initial-Schädigung vor, d.h. der Erwartungswert und die Varianz von  $\delta(t)$  sind jeweils Null, d.h.  $E(\delta(0)) = 0$  und  $Var(\delta(0)) = 0$ . Die Zunahme der Schädigung  $\delta(t)$  ergibt sich dann für jedes Quantil in Abhängigkeit von der gewählten Schädigungshypothese und des Lebensdauer-Last-Modells. Ausgehend von der Initial-Schädigung wird in den praktischen Fällen sowohl der Erwartungswert  $E(\delta(t))$  als auch die Varianz  $Var(\delta(t))$  der Schädigung über der Zeit anwachsen.

### Berücksichtigung eines Lastsprungs zwischen zwei konstanten Lastniveaus

Die variable Betriebsbelastung wird als mehrstufige Belastung in Form eines Lastkollektivs  $s(t)$  angenommen, welches aus endlich vielen konstanten Lastniveaus  $s_i$ ,  $i = 1 \dots N_s$ , der

Dauer  $\tau_{s_i}$ , besteht. Ein Lastsprung zum Zeitpunkt  $t_i$  von einem Lastniveau  $s_i(t_i)$  zum nachfolgenden Lastniveau  $s_{i+1}(t_i)$  erfolgt unmittelbar. Der Lastsprung selbst,  $\Delta s_i = s_{i+1}(t_i) - s_i(t_i)$ , trägt nicht zur Schädigung bei.

Bei einem Lastsprung gelten die folgenden Übergangsbedingungen:

Bei einem Lastsprung ist die erreichte Schädigungsverteilung  $F_{\delta,i}(d, t_i)$  im bisherigen Lastniveau gleich der Schädigungsverteilung  $F_{\delta,i+1}(d, t_i)$  im nächsten Lastniveau. Somit gilt für alle Quantile  $d_q(t)$ ,  $0 < q < 1$ , der Schädigungsverteilung  $F_{\delta}(d, t)$  entsprechend  $d_{q,i}(t_i) = d_{q,i+1}(t_i)$ ,  $0 < q < 1$ . Bei einem Lastsprung erfolgt somit für alle Quantile keine sprunghafte Veränderung des Schädigungsniveaus.

Der weitere Anstieg der Schädigung, d.h. der Schädigungsgradient  $dd_{q,i+1}(t)/dt$ , im nächsten Lastniveau ist für alle Quantile  $d_{q,i+1}(t)$ ,  $0 < q < 1$ , gleich dem Gradient, der in diesem Lastniveau vorliegen würden, wenn das Niveau vom Zeitpunkt  $t = 0$  an ohne Unterbrechung konstant vorliegen würde. Der Schädigungsgradient  $dd_q(t)/dt$  entspricht folglich für alle Quantile  $d_q(t)$ ,  $0 < q < 1$ , dem Gradienten, der bei einer einstufigen Belastung bei einem bestimmten Schädigungsniveau vorliegt. Der weitere Anstieg der Schädigung ab einer Laststufe ist somit nur von der Schädigung abhängig, die bis zur Laststufe erreicht wurde, d.h. er ist unabhängig vom Verlauf des bisherigen Anstiegs. Die erreichte Schädigung ist folglich ein Laststufen-übergreifendes kumulierendes Merkmal des Schädigungsprozesses in einem Bauteil. Die zeitliche Entwicklung der Schädigung  $\delta(t)$  in Abhängigkeit des Lastkollektivs  $s(t)$  wird durch die Schädigungsverteilung  $F_{\delta}(d, t)$  beschrieben, die sich aufgrund der zuvor beschriebenen Zusammenhänge ergibt.

Mit einem Übergang zu infinitesimal kleinen Lastsprüngen, d.h.  $\Delta s_i \rightarrow 0$ , lässt sich ein Übergang zu stetigen Lastverläufen  $s(t)$  erreichen. Gleiches gilt beim Übergang zu infinitesimal kleinen Laststufendauern, also für  $\Delta \tau_i \rightarrow 0$ .

### **Ermittlung einer zeitabhängigen Funktion der Ausfallwahrscheinlichkeit bzw. der Zuverlässigkeit**

Unter Berücksichtigung des Ausfallkriteriums (siehe den entsprechenden vorherigen Abschnitt) lassen sich auf Basis der sich ergebenden Schädigungsverteilung  $F_{\delta}(d, t)$  die Quantile  $t_{\tau,q} = F_{\tau}^{-1}(q)$ ,  $0 < q < 1$ , der Verteilungsfunktion  $F_{\tau}(t) = \mathbb{P}\{\tau \leq t\}$  ermitteln, welche die Lebensdauer bei variabler Belastung  $s(t)$  beschreibt, wie Bild 1 oben zeigt. Der Verlauf der Verteilungsfunktion  $F_{\tau}(t)$  ist durch ihre Quantile  $t_{\tau,q}$ ,  $0 < q < 1$ , vollständig beschrieben.

Die Lebensdauer bei variabler Belastung ist somit ebenfalls eine Zufallsgröße  $\tau$ , die durch die Verteilungsfunktion  $F_\tau(t)$  bzw. Dichte  $f_\tau(t)$  beschrieben wird. Die zeitabhängige Zuverlässigkeit  $R_\tau(t)$ , die sich bei variabler Belastung  $s(t)$  ergibt, berechnet sich aus dem Zusammenhang  $R_\tau(t) = 1 - F_\tau(t)$ .




Bild 1: Schädigung als stochastischer Prozess und daraus resultierende Lebensdauer

#### 4. Vergleich der Methoden

Im Folgenden werden anhand einiger Kriterien die in Kapitel 2 vorgestellten Methoden und die neu konzipierte Methode miteinander qualitativ verglichen. Hierbei werden Kriterien betrachtet, die den Schädigungsprozess, die Belastung, das Lebensdauermodell und die allgemeinen Eigenschaften der Methoden betreffen. Abschließend wird auf erste Ergebnisse hingewiesen, die sich aus Untersuchungen zur Verifikation der Methoden ergeben haben.

#### Schädigungsprozess

Bei den Methoden nach Dubi und Mettas wird der Schädigungsprozess, der einem Ausfall vorangeht, nicht berücksichtigt. Bei den Methoden nach Palmgren-Miner, Rathod et al., Zhu

et al. und bei der in diesem Betrag vorgestellten Methode wird der Schädigungsprozess berücksichtigt. Hierbei verwendet die Methode nach Rathod et al. die lineare Schädigungsakkumulation nach Palmgren-Miner. Die Methode nach Zhu et al. berücksichtigt eine nicht-lineare Akkumulation der Schädigung. Mit der vorgestellten Methode lassen sich sowohl lineare als auch nicht-lineare Schädigungshypothesen verwenden. Bei der Methode nach Palmgren-Miner ist die berechnete Schädigung ein deterministischer Wert. Die Methoden nach Rathod et al, Zhu et al. und die neue Methode betrachten die Schädigung als Zufallsgröße und ermöglichen eine probabilistische Modellierung des Schädigungsprozesses.

## Belastung

Alle verglichenen Methoden sind in der Lage, eine variable Belastung zu berücksichtigen. Die Methoden nach Dubi, Palmgren-Miner, Rathod et al. und Zhu et al. gehen bei der Beschreibung der Belastung von einem mehrstufigen Belastungskollektiv aus. Bei der Methode nach Mettas kann darüber hinaus die Belastung auch in Form einer allgemeinen zeitabhängigen Funktion vorliegen. In der Konzeption der neuen Methode wird der Übergang von einem mehrstufigen Lastkollektiv zu einer allgemeinen zeitabhängigen Belastungsfunktion aufgezeigt. Bei einem Lastsprung von einem Lastniveau  $s_i$  zum nachfolgenden Lastniveau  $s_{i+1}$  zu einem Zeitpunkt  $t_i$  werden bei den betrachteten Methoden unterschiedliche Übergangsbedingungen berücksichtigt. Bei der Methode nach Dubi wird die erreichte Alterung  $Age_i$ , die der erreichten Ausfallwahrscheinlichkeit entspricht, d.h.  $Age_i(t_i) = F_i(t_i)$ , bei der Bestimmung der bedingten Verteilungsfunktion  $F_{i+1}(t|t_i)$ ,  $t \geq t_i$ , verwendet, die die verbleibende Lebensdauer im nachfolgenden Lastniveau beschreibt. Bei der Methode nach Mettas wird die erreichte Ausfallwahrscheinlichkeit  $F_i(t_i)$  benutzt, um die Verteilungsfunktion, die die Lebensdauer auf dem Lastniveau der nachfolgenden Laststufe beschreibt, zeitlich so zu transformieren, dass die transformierte Verteilungsfunktion  $F_{i+1}^*(t)$  zum Zeitpunkt  $t_i$  ebenfalls die Ausfallwahrscheinlichkeit  $F_i$  besitzt, d.h.  $F_i(t_i) = F_{i+1}^*(t_i)$ . Bei der Methode nach Palmgren-Miner bildet eine erreichte Schädigung  $d_i(t_i)$  im Lastniveau  $s_i$  den Ausgangspunkt für die weitere Kumulierung der Schädigung im nachfolgenden Lastniveau  $s_{i+1}$ , d.h.  $d_i(t_i) = d_{i+1}(t_i)$ . Bei der Methode nach Rathod et al. und nach Zhu et al. bildet ebenfalls die Schädigung die Übergangsbedingung an einer Laststufe. Hierbei wird bei beiden Methoden der Erwartungswert der stochastisch verteilten Schädigung verwendet, um die Schädigung am Lastsprung zu berechnen, d.h.  $d_{i,mean}(t_i) = d_{i+1,mean}(t_i)$ . Im Gegensatz dazu wird eine erreichte Streuung der Schädigung im Lastniveau  $s_i$  im nachfolgenden Lastniveau  $s_{i+1}$  nicht direkt weiterverwendet. In der neu vorgestellten Me-

thode werden für alle Quantile der stochastisch verteilten Schädigung die erreichte Schädigung im Lastniveau  $s_i$  als Startwert im nachfolgenden Lastniveau  $s_{i+1}$  verwendet, d.h.  $d_{i,q}(t_i) = d_{i+1,q}(t_i)$ ,  $0 < q < 1$ . Hierdurch wird die erreichte Streuung der Schädigung beim Übergang in das nachfolgende Lastniveau beibehalten. Bei der vorgestellten Methode ergibt sich als weitere Randbedingung bei einem Lastsprung zum Zeitpunkt  $t_i$ , dass die Ausfallwahrscheinlichkeit zum Zeitpunkt  $t_i$  den gleichen Wert besitzt, d.h.  $F_{\tau,i}(t_i) = F_{\tau,i+1}(t_i)$ .

### Lebensdauermodell

Die Methoden nach Mettas, Rathod et al., Zhu et al. und die vorgestellte Methode verwenden ein probabilistisches Lebensdauer-Last-Modell. Die Methode nach Palmgren-Miner nutzt ein bestimmtes Quantil eines probabilistischen Lebensdauer-Last-Modells. Die Methode nach Dubi verwendet in den Laststufen jeweils individuelle Verteilungsfunktionen zur Beschreibung der Lebensdauer.

### Allgemeine Eigenschaften der Methoden

Alle verglichenen Methoden, bis auf die Methode nach Palmgren-Miner, ermöglichen die Berechnung der Ausfallwahrscheinlichkeit bzw. der Zuverlässigkeit bei variabler Belastung als zeitabhängige Funktion, d.h. die Lebensdauer wird als stochastische Zufallsgröße betrachtet. Im Gegensatz dazu ermittelt die Methode nach Palmgren-Miner als Ergebnis eine Lebensdauer, für die das Quantil der Ausfallwahrscheinlichkeit gilt, welches für das Lebensdauer-Last-Modell verwendet wurde.

Für die Methoden nach Dubi und Mettas ist es hierbei nicht notwendig ein Ausfallkriterium zu verwenden, da sie den Schädigungsprozess nicht berücksichtigen. Die anderen Methoden, die auf der Modellierung des Schädigungsprozesses basieren, benötigen ein solches Ausfallkriterium, um Ausfallzeiten zu bestimmen. Hierbei verwendet die Methode nach Palmgren-Miner eine bestimmte Grenzschädigung als Ausfallbedingung. Bei den Methoden nach Rathod et al., Zhu et al. wird die Grenzschädigung als Zufallsgröße angenommen. Die Ausfallwahrscheinlichkeit zu einem bestimmten Zeitpunkt ergibt sich hierbei durch eine Interferenz von erreichter stochastischer Schädigung und Grenzschädigung. Bei der neu vorgestellten Methode kann für die Grenzschädigung sowohl ein deterministischer Wert als auch eine stochastische Zufallsgröße angenommen werden. Im zweiten Fall ergibt sich die Ausfallwahrscheinlichkeit zu einem bestimmten Zeitpunkt ebenfalls durch eine Interferenz von erreichter stochastischer Schädigung und Grenzschädigung.

## Erste Ergebnisse der Verifikation der Methoden

Erste Untersuchungen zur Verifikation der Methoden, die in diesem Vergleich neben der neuen Methode betrachtet werden, haben ergeben, dass sich für bestimmte Annahmen dieser Methoden bei der Berechnung der zeitabhängigen Zuverlässigkeit bei variabler Belastung Unplausibilitäten ergeben. Beispielsweise ist das bei den Methoden nach Rathod et al. und Zhu et al. bei der Berechnung der zeitabhängigen Zunahme der Varianz der Schädigungsverteilung der Fall. Es hat sich ebenfalls gezeigt, dass die Annahme einer bestimmten Verteilungsfunktion für die Schädigung allenfalls als Näherung gerechtfertigt werden kann. Bei den Methoden nach Dubi und Mettas ergeben sich bei einem zusätzlich angenommenen Schädigungsprozess sprunghafte Veränderungen der erreichten Schädigung an den Lastsprüngen des Belastungsprofils. Dies widerspricht der Annahme, dass ein Zuwachs der Schädigung monoton und stetig erfolgt.

## 5. Zusammenfassung

Die Konzeption der vorgestellten neuen Methode zur Berechnung der zeitabhängigen Zuverlässigkeit bei variabler Belastung wird anhand einiger wesentlichen Elemente beschrieben. Die Schädigung eines Bauteils wird hierbei als stochastische Größe angenommen und die weitere Zunahme der Schädigung als stochastischer Prozess. Die Ermittlung der Schädigungsverteilung in einem Lastniveau erfolgt u.a. auf Basis eines probabilistischen Lebensdauer-Last-Modells. Die zeitliche Entwicklung der Schädigungsverteilung ist abhängig vom vorliegenden Belastungsprofil. Erreicht die Schädigung eine bestimmte Grenzschädigung, so lässt sich aus den Quantilen der Schädigungsverteilung die Lebensdauer bei variabler Belastung als Zufallsgröße eindeutig charakterisieren. Die zeitabhängige Zuverlässigkeit bei variabler Belastung ist eine mögliche Beschreibungsform dieser Lebensdauer.

Ein qualitativer Vergleich der neu konzipierten Methode mit mehreren bekannten Methoden erfolgt anhand wesentlicher Kriterien, die die Modellannahmen der Methoden betreffen. Insbesondere werden Annahmen zum Schädigungsprozess, zur Belastung, zum Lebensdauermodell und weitere allgemeinen Eigenschaften der Methoden verglichen. Dabei werden sowohl die Gemeinsamkeiten als auch die Unterschiede zwischen den Methoden verdeutlicht. Eine spezifische Eigenschaft der vorgestellten Methode ist, dass aufgrund der getroffenen Annahmen der Schädigungsanstieg über der Zeit für alle Quantile der Schädigungsverteilung monoton steigend und stetig ist. Ebenso ist die zeitabhängige Ausfallwahrscheinlichkeit monoton steigend und stetig. Diese Eigenschaften der Schädigung und der Ausfallwahrscheinlichkeit gelten auch bei Lastsprüngen. Hierdurch unterscheidet sich die vorgestellte Methode von den anderen betrachteten Methoden.

Die vorgestellte Methode ermöglicht die probabilistische Erweiterung von in der Praxis bewährten Schädigungsakkumulationshypothesen mit dem Ziel, typische Beschreibungsgrößen der Lebensdauer bzw. der Zuverlässigkeit bei variabler Belastung zu berechnen. Diese lassen sich für die zuverlässigkeitstechnische Bewertung eines Bauteils einsetzen sowie in weiterführenden Zuverlässigkeitsmethoden einsetzen. Die Methode schlägt auf diese Weise eine Brücke zwischen den Methoden der Betriebsfestigkeitsrechnung und der Zuverlässigkeitstechnik. Aktuell erfolgen weitergehende Untersuchungen zur Verifizierung und Validierung der vorgestellten Methode. Hierbei sind unter anderem auch quantitative Vergleiche der Ergebnisse der vorgestellten Methode mit den bereits bekannten Methoden vorgesehen, beispielsweise auch unter Berücksichtigung der statistischen Unsicherheit.

## Literatur

- [1] Nelson, W. B. (2004). *Accelerated Testing: Statistical Models, Test Plans, and Data Analysis*. John Wiley & Sons.
- [2] Yang, G. (2007). *Life cycle reliability engineering*. John Wiley & Sons
- [3] Haibach, E. (2006). *Betriebsfestigkeit*. Springer-Verlag, Berlin, Heidelberg
- [4] Dubi, A. (2000). *Monte Carlo applications in systems engineering*. Wiley.
- [5] Rieker, T.; Zeiler, P.; Bertsche, B.: Reliability Analysis of a Hybrid Car Drive System with ECSPN. *Proc. 2015 Annual Reliability and Maintainability Symposium (RAMS 2015)*, 26th-29th January 2015, Palm Harbor, FL, USA, pp. 562-568, doi: 10.1109/RAMS.2015.7105197.
- [6] Mettas, A. (2005). Reliability predictions based on customer usage stress profiles. In *Proc. Annual Reliability and Maintainability Symposium (RAMS 2005)*, pp. 20-25.
- [7] Zeiler, P.; Eric, A.: Reliability at Use Condition Considering the Statistical Uncertainty and Distribution of Life-Stress Model and a Sample of Load Spectra. *Proceedings of the 30th European Safety and Reliability Conference and the 15th Probabilistic Safety Assessment and Management Conference*, 01.11. – 05.11.2020, Venedig (online), ISBN: 978-981-14-8593-0.
- [8] Palmgren, A. (1924). Die Lebensdauer von Kugellagern, *VDI-Zeitschrift* 69, S. 339-341.
- [9] Miner, M. A. (1945). Cumulative damage in fatigue, *Trans. ASME, Journal of Applied Mechanics* 12, pp. 159-164.
- [10] Fatemi, A., & Yang, L. (1998). Cumulative fatigue damage and life prediction theories: a survey of the state of the art for homogeneous materials. *International Journal of Fatigue*, 20(1), 9-34. [https://doi.org/10.1016/S0142-1123\(97\)00081-9](https://doi.org/10.1016/S0142-1123(97)00081-9)



- [11] Fissolo, A., Gourdin, C., Chen, Y., Perez, G., & Stelmaszyk, J. M. (2015). Investigations into the cumulative fatigue life of an AISI 304L austenitic stainless steel used for pressure water reactors: Application of a double linear damage rule. *International Journal of Fatigue*, 77, 199-215. <https://doi.org/10.1016/j.ijfatigue.2015.02.010>
- [12] Rathod, V., Yadav, O. P., Rathore, A., & Jain, R. (2011). Probabilistic modeling of fatigue damage accumulation for reliability prediction. *Journal of Quality and Reliability Engineering*, 2011. <https://doi.org/10.1155/2011/718901>
- [13] Zhu, S. P., Huang, H. Z., Li, Y., Liu, Y., & Yang, Y. (2015). Probabilistic modeling of damage accumulation for time-dependent fatigue reliability analysis of railway axle steels. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 229(1), 23-33. <https://doi.org/10.1177/0954409713496772>



# **Nutzung von Neuronalen Netzen zur Effizienzsteigerung in der optimalen Zuverlässigkeitstestplanung**

## **Application of Neural Networks for Increased Simulation Efficiency in Optimal Test Planning**

**Philipp Mell, Thomas Herzig, Prof. Dr.-Ing. Bernd Bertsche,**  
Institut für Maschinenelemente, Universität Stuttgart

### **Kurzfassung**

Lebensdauertests sind zur Sicherstellung der Zuverlässigkeit eines Produkts unverzichtbar. In der Praxis wird versucht, Testpläne so zu entwerfen, dass sie unter gegebenen Zuverlässigkeits-, Zeit- und Kostenanforderungen optimale Ergebnisse liefern. Selbst wenn die Lebensdauerparameter und das Ausfallverhalten als bekanntes Vorwissen berücksichtigt werden, verbleiben zahlreiche Kombinationsmöglichkeiten der Testparameter. Aufgrund der stochastischen Natur der Lebensdauer ist auch die nachweisbare Lebensdauer eines Zuverlässigkeitstests selbst als Zufallsvariable aufzufassen. Aus diesem Grund wird die Wahrscheinlichkeit für einen erfolgreichen Test, die sogenannte Probability of Test Success, als grundlegende Kenngröße in der Testplanung verwendet. Um diese zu ermitteln, muss in der Testplanung jede betrachtete Testkonfiguration mehrmals simuliert werden, was einen hohen Rechenaufwand zur Folge hat. Zur Schätzung der nachweisbaren Lebensdauer werden künstliche neuronale Netze trainiert, welche den Simulationsaufwand und die Anzahl simulierter Testpläne verringern.

### **Abstract**

Reliability demonstration tests are essential to ensure the reliability of a product. In practice, test plans are therefore designed in such a way that they deliver optimum results under prior knowledge and given reliability requirements. Even with prior knowledge on the lifetime and failure behavior of a component, numerous possible combinations of test parameters remain. Due to the stochastic nature of lifetime, the demonstrated lifetime of a reliability test can be seen as a random variable. Therefore, the probability of a successful test is quantified with the Probability of Test Success. To calculate this quantity, each test configuration has to be simulated multiple times, which results in a high computational effort. Given these preconditions, artificial neural networks are trained to substantially reduce the simulation effort and the number of simulated test plans by estimating the demonstrated lifetime.

## 1. Problemstellung in der optimalen Erprobungsplanung

Lebensdauertests dienen der Sicherstellung der Zuverlässigkeit eines Produkts. In der Praxis sollten Testpläne so entworfen werden, dass sie bezüglich gegebener Zuverlässigkeits-, Zeit- und Kostenanforderungen optimale Ergebnisse liefern [1-3]. Bezüglich eines beliebigen Testplans besteht daher stets die Fragestellung, ob ein anderer Testplan unter den gegebenen Voraussetzungen optimal ist bezüglich einer bestimmten Zielgröße. Der kostenoptimale Testplan beispielsweise ist derjenige, welcher unter Einhaltung der maximal zulässigen Testdauer und des geforderten Mindestnachweiszeitpunktes die niedrigsten Ausgaben für Prüflinge, Prüfstände, Arbeitszeit etc. verursacht.

Testpläne werden anhand der Teststrategien zwischen Success Run, unbeschleunigtem und beschleunigtem End-of-Life-Test (EoL-Test) mit oder ohne Zensierung unterschieden [1]. Weiterhin können Testparameter wie Prüflingszahl, Anzahl und Höhe der Lastniveaus, Raffungsfaktor, Zensierungsart und -anteil beliebig kombiniert werden. Bereits anhand dieser Variablen ergeben sich zahlreiche Kombinationsmöglichkeiten. Ebenso sind die geforderte Produktzuverlässigkeit sowie die Aussagewahrscheinlichkeit für einen erfolgreichen Nachweis einzuhalten [2]. Die nachweisbare Lebensdauer eines Zuverlässigkeitstests ist durch den Stichprobenfehler zufällig verteilt, sie verändert sich also bei wiederholter Durchführung des Tests. Diese Streuung wird mit der Probability of Test Success ( $P_{ts}$ , Bild 1) berücksichtigt. Sie quantifiziert, mit welcher Wahrscheinlichkeit ein Testplan den geforderten Nachweiszeitpunkt  $t_{NP}$  tatsächlich nachweisen kann [3] und bildet die zentrale Bewertungsgröße der Zuverlässigkeitstestplanung. Zur Vorhersage des Nachweiszeitpunktes unter Einhaltung einer minimal zu erreichenden  $P_{ts}$  ist eine repetitive Simulation erforderlich. Lebensdauertests können beschleunigt werden, indem sie unter höherer Last als im Feld durchgeführt werden. Zum Lebensdauernachweis auf Feldlast ist neben dem Ausfallverhalten daher auch ein Lebensdauermodell wie in Bild 2 als Vorwissen notwendig. In der Folge ergibt sich eine Vielzahl an Einflussfaktoren auf die Optimalität eines Testplans.




Bild 1: Jede Durchführung eines Zuverlässigkeitstests liefert eine eigene nachweisbare Lebensdauer  $t^*$ , deren  $(1-P_{ts})$ -Quantil der gesuchte Nachweiszeitpunkt  $t_{NP}$  ist




Bild 2: Extrapolation der Lebensdauer auf Feldlastniveau ( $V_0$ ) aus den Testergebnissen auf zwei beschleunigten Lastniveaus ( $V_L$ ,  $V_H$ ) mithilfe des Wöhlerexponenten  $k$

Ein am Institut für Maschinenelemente (IMA) der Universität Stuttgart entwickeltes Simulationsprogramm untersucht alle Kombinationen von Testplanungsparametern innerhalb der vom Benutzer vorgegebenen Grenzen [2]. Die  $P_{ts}$  wird dabei als Teil der Zuverlässigkeitsanforderung betrachtet, da nur Testpläne erwünscht sind, die mit hoher Wahrscheinlichkeit das Zuverlässigkeitsziel nachweisen. Für jede dieser Konfigurationen werden analog zu [2], [3] iterativ zufällige Ausfallzeiten anhand des Vorwissens über das Produkt erzeugt. Durch eine Maximum-Likelihood-Schätzung wird die nachweisbare Lebensdauer auf Feldlastniveau ermittelt [4]. Dieses Vorgehen wird in einer Monte-Carlo-(MC-)Simulation wiederholt, bis Nachweiszeitpunkts gegen einen Grenzwert konvergiert ist. In dieser Simulation sind ca. 10.000 Iterationen je Testkonfiguration notwendig, was einen großen Rechenaufwand bedeutet. Der Algorithmus wird für jede Testkonfiguration durchgeführt. Diese Arbeit beschränkt sich auf vollständige, d. h. unzensierte, beschleunigte EoL-Tests auf zwei Lastniveaus, da sie den grundlegenden Anwendungsfall darstellen. Als Ausfallverteilung des Produkts wird eine zweiparametrische Weibullverteilung angenommen, als Lebensdauermodell das Inverse Power Law (IPL) [5], [6]. Als Einflussfaktoren auf die Optimalität eines Testplans ergeben sich somit folgende Variablen(gruppen): p

- |  |   |                                      |
|--|---|--------------------------------------|
| 1. Anzahl der Prüflinge auf dem niedrigen Lastniveau $n_L$ | } | Prüflingsverteilung<br>des Testplans |
| 2. Anzahl der Prüflinge auf dem hohen Lastniveau $n_H$     |   |                                      |
| 3. Relative Höhe des niedrigen Lastniveaus $V_L$           |   |                                      |
| 4. Formparameter der Ausfallverteilung $b$                 | } | Vorwissen über das<br>Produkt        |
| 5. Exponent des Lebensdauermodells $k$                     |   |                                      |
| 6. Zuverlässigkeit $R$                                     | } | Zuverlässigkeits-<br>anforderung     |
| 7. Aussagewahrscheinlichkeit $P_A$                         |   |                                      |
| 8. Probability of Test Success $P_{ts}$                    |   |                                      |

Somit ergibt sich eine beträchtliche Menge möglicher Testkonfigurationen, deren Simulationsdauer zu hoch für praktische Anwendungen ist. Das übergeordnete Ziel ist daher, die Anzahl der Testkonfigurationen in der MC-Simulation deutlich zu verringern und somit die Praxistauglichkeit des Algorithmus zu erhöhen. Dies soll durch eine Vorauswahl mit deutlich höherer Geschwindigkeit bei geringerer Genauigkeit geschehen, welche nur erfolgversprechende Testkonfigurationen für die MC-Simulation zulässt und die übrigen verwirft.

Die Vorauswahl basiert auf einer Schätzung der nachweisbaren Lebensdauer  $t_{NP}$  mit Hilfe eines künstlichen neuronalen Netzes. Dafür werden mehrere neuronale Netze mit verschiedenen Eigenschaften untersucht. Anhand objektiver Bewertungskriterien wird ermittelt, welches dieser Netze die Aufgabe der Lebensdauerschätzung am besten erfüllt. Anschließend wird der Einfluss einzelner Netzparameter diskutiert. Anhand eines Rechenbeispiels wird untersucht, inwieweit die Vorauswahl geeigneter Testpläne den Algorithmus zur Ermittlung eines optimalen Testplans beschleunigt.

## 2. Neuronale Netze in der Testplanung

Künstliche neuronale Netze, kurz neuronale Netze (NN), können eingesetzt werden, um komplexe oder algebraisch nicht sinnvoll formulierbare Zusammenhänge auf Basis vorhandener Daten zu erlernen und auf neue Daten möglichst korrekt anzuwenden [7 bis 9]. Da diese Beschreibung auf die vorliegende Problemstellung zutrifft, wird ihr Potenzial zum Einsatz in der Testplanung untersucht.

Prinzipiell besteht jedes NN aus Neuronen in mehreren Schichten (engl. Layer), die mit Kanten verbunden sind (Bild 3). Die Gewichte (engl. Weights) der Kanten und Festwerte (engl. Biases) der Neuronen werden beim Training des NN schrittweise so modifiziert, dass




Bild 3: Struktur eines künstlichen neuronalen Netzes

sie die gewünschte Aufgabe erfüllen. In diesem Fall ist diese Aufgabe die Ermittlung eines Schätzwertes für den Nachweiszeitpunkt  $t_{NP}$  eines Produkts bei bestimmten Einstellungen der Testparameter. Als Eingangsgrößen für das Netz dienen die im vorigen Abschnitt genannten Größen. Da das Training anhand bekannter Paarungen von Ein- und Ausgangsdaten erfolgt, spricht man von überwachtem Lernen. Ein Anteil an den zur Verfügung stehenden Daten werden als Testdaten zurückgehalten, mit denen anschließend die Performance des trainierten Netzes bewertet wird. Diese und weitere Maßnahmen sollen dem Auswendiglernen von Daten durch das Netz, dem sog. Overfitting, entgegenwirken. Die Trainingsdaten werden dem NN in mehreren Durchgängen (Epochen) präsentiert.

Das hier vorliegende Problem erfordert ein Netz zur Regressionsanalyse, was einen vergleichsweise einfachen Anwendungsfall darstellt. Daher werden im Folgenden nur einfache mehrschichtige Topologien (engl. multilayer feedforward neural networks) wie in Bild 3 betrachtet.

Der Designspielraum bei dieser Art von NN betrifft

- die Anzahl an Layers und der jeweiligen Neuronen,
- die verwendete Aktivierungsfunktion,
- das Lernverfahren und
- die Qualität, Menge und Aufteilung der verwendeten Daten.

### 3. Datenbasis

Von elementarer Bedeutung für jede statistische Schätzung sind die Qualität und Quantität der zugrundeliegenden Daten. Dies ist auch bei Einsatz eines NN zur Regression nicht anders. Insgesamt stehen gut 100.000 Datenpunkte zur Verfügung. Der Bereich, in dem die genannten Parameter variiert wurden, ist in Tabelle 1 gegeben.

Um die Qualität der Daten sicherzustellen, wurden so viele Iterationen in der MC-Simulation durchgeführt, bis anhand fixer Grenzwerte Konvergenz gegen einen konkreten Wert festgestellt wurde. In einer Voruntersuchung wurde nachgewiesen, dass der verbliebene Fehler mit geringer Varianz normalverteilt ist und das Trainingsergebnis somit nicht verfälscht. Als Maßnahme gegen Overfitting wurden einige Versuchspunkte mehrmals simuliert, was dem Ergebnis ein künstliches Rauschen aufgebracht hat.

Tabelle 1: Definition des untersuchten Parameterraums

Größe	$n_L$	$n_H$	$V_L$	$b$	$k$	$R$	$P_A$	$P_{ts}$
Wert (min.)	3	3	0,25	1,05	2,00	45,0 %	45,0 %	45,0 %
Wert (max.)	55	55	0,92	8,00	6,00	99,0 %	99,5 %	99,5 %

Der erste Teil der Datenbasis setzt sich aus ca. 80.000 praxisrelevanten Parameterstufenkombinationen und dazwischenliegende Stützstellen zusammen. Der zweite Teil besteht aus 10.000 Datenpunkten, die mit Hilfe eines quasizufälligen Algorithmus so erzeugt wurden, dass sie den Parameterraum möglichst gleichmäßig ausfüllen.

#### 4. Untersuchte Varianten neuronaler Netze

Es wurden insgesamt 61 verschiedene NN untersucht. Die Varianten unterscheiden sich in den in Tabelle 2 gezeigten Parametern. Die Anzahl an Hidden Layers ist auf drei limitiert, um einerseits ein möglichst generalisierendes Netz für die vorliegende Regressionsaufgabe zu erhalten und andererseits den Rechenaufwand zu begrenzen. Pro Layer werden bis zu 40 Neuronen verwendet. Die Eingänge entsprechen den acht in Tabelle 1 genannten Parametern, die Ausgangsgröße ist der Nachweiszeitpunkt.

Als Aktivierungsfunktionen kommen eine sigmoidale Funktion (Tangens hyperbolicus) und eine lineare Funktion (Rectified Linear Unit, ReLU) zum Einsatz. Erstere zeichnet sich durch eine höhere Genauigkeit aus, zweite ist dagegen deutlich weniger rechenintensiv – was die Anzahl möglicher Neuronen erhöht – und stabiler in der Berechnung [7]. Die Aktivierungsfunktion ist für alle Neuronen einer Netzvariante identisch. Als Trainingsalgorithmus werden sowohl Levenberg-Marquardt (LM) als auch Bayesian Regularization (BR) eingesetzt. Ersterer kombiniert das Gradienten- mit dem Gauß-Newton-Verfahren, während letzterer als weitere Maßnahme gegen Overfitting wenige bzw. kleine Kantengewichte und Biases bevorzugt. Für die detaillierte Beschreibung dieser beiden Verfahren wird auf die Literatur verwiesen [10 bis 13].

Tabelle 2: Eigenschaften der erzeugten neuronalen Netze; \* = identisch für alle Varianten

Netzeigenschaft	Varianten
Inputs*	8
Outputs*	1
Anzahl Hidden Layer	1; 2; 3
Neuronen je Hidden Layer	1; 2; 3; 4; 5; 6; 7; 8; 9; 10; 12; 16; 24; 30; 40
Aktivierungsfunktion	Sigmoid (Tangens hyperbolicus); ReLU
Trainingsalgorithmus	Levenberg-Marquardt (LM); Bayesian Regularization (BR)
Performanceindikator*	MSE (prozentual)
Aufteilung in Trainings- und Validierungsdaten (nur LM)	70:30; 80:20; 82:18
Umfang Trainingsdatensatz	3.937 – 10.000



Bei allen Netzen wird unterschieden zwischen den Daten, die zum Training verwendet werden (Trainingsdaten), sowie jenen, die zum Testen des fertig trainierten Netzes eingesetzt werden (Testdaten). Die Zuordnung bzw. prozentuale Aufteilung wird über die verschiedenen Netzvarianten geändert. Aufgrund der Ausgestaltung der Abbruchkriterien für das Training ist es für den LM-Algorithmus notwendig, zusätzlich einen Teil der Trainingsdaten vorzuhalten und zur Validierung vorzuhalten (Validierungsdaten). Auch deren Anteil wird variiert.

Nach Abschluss des Trainingsprozesses wird die Performance jedes NN anhand eines oder mehrerer Datensätze bewertet. Übliche Performanceindikatoren sind der Mittlere Quadratische Fehler (Mean Squared Error, MSE) bzw. dessen Wurzel (RMSE, Root Mean Square Error) sowie das Bestimmtheitsmaß  $R^2$ , welche auch hier eingesetzt werden [7].  $R^2$  gibt dabei an, welcher Anteil der Variation der Netzoutputs mit tatsächlich unterschiedlichen Zielwerten erklärt werden kann. Für den MSE wird die Abweichung in jedem Datenpunkt normalisiert, sodass höhere Ausgangswerte keinen größeren Einfluss auf das Ergebnis haben als kleinere.

## 5. Ergebnisse

Die Performance der erzeugten Netzvarianten wurde anhand des MSE und des Bestimmtheitsmaßes  $R^2$  verglichen. Als Testdaten kam eine Sammlung von ca. 80.000 Datenpunkten aus verschiedenen Parameterstufenkombinationen zum Einsatz. Im Folgenden sollen die Ergebnisse der beiden Netzvarianten mit dem besten Resultat exemplarisch dargestellt werden. Die wichtigsten Erkenntnisse werden anschließend diskutiert.

Die beiden Netzvarianten A und B, welche den niedrigsten MSE liefern, setzen sich aus zwei Hidden Layers zu 40 und 16 Neuronen (A) beziehungsweise aus drei Hidden Layers mit 16, 8 und 4 Neuronen (B) zusammen. Netz B ist beispielhaft in Bild 4 dargestellt. Dicke und Farbe der Kanten spiegeln dabei die relative Größe und das Vorzeichen der jeweiligen Gewichte wider. Beide Netzvarianten verwendeten den BR-Lernalgorithmus und erhielten einen quasizufälligen Datensatz statt Parameterstufenkombinationen zum Training. Netz A nutzt die ReLU-Aktivierungsfunktion, Netz B die Sigmoidfunktion.

Die beiden Netze erzeugen bei Anwendung auf das Testdatenset einen mittleren Fehler (RMSE) von ca. 1 %, siehe Tabelle 3. Die jeweiligen Abweichungen sind nahezu normalverteilt mit Mittelwert 0 und weisen nur wenige Ausreißer auf (Bild 5). Die Trainingszeit von Netz A war mit 178 gegenüber 944 Epochen, die jeweils ebenfalls kürzer waren, deutlich niedriger. Netz B ermittelt in Fällen verschwindender Nachweiszeitpunkte vereinzelt geringe negative Ergebnisse, während diese bei Netz A nie kleiner Null sind.




Bild 4: Grafische Darstellung der Kantengewichte von Netzvariante B nach Betrag (Dicke) und Vorzeichen (blau: positiv, rot: negativ)

Tabelle 3: Ergebnisse der beiden besten neuronalen Netze, ausgewertet an einem Datensatz mit 80.000 Versuchspunkten

Performanceindikator	Netzvariante A	Netzvariante B
MSE	1,35e-4	9,98e-5
RMSE	1,16 %	1,00 %
R <sup>2</sup>	99,77 %	99,83 %




Bild 5: Histogramm der prozentualen Abweichung zwischen den Ausgabewerten von Netzvariante B und den gewünschten Ergebnissen für den Nachweiszeitpunkt  $t_{NP}$ .

Die Anwendung eines der erzeugten NN zur Vorauswahl von Testplänen im Rahmen der optimalen Erprobungsplanung wurde in einem Berechnungsbeispiel mit 727 möglichen Testplänen untersucht. Die Ergebnisschätzung ermöglichte es, die Anzahl zu betrachtender Testpläne auf 55 zu reduzieren, da sie den geforderten Mindestnachweiszeitpunkt nicht darstellen können. Dies ging einher mit einer Verringerung der Rechenzeit von 77 auf vier Minuten (ca. Faktor 19). Die gefundenen optimalen Testpläne bezüglich Nachweiszeitpunkt, Kosten und Testdauer änderten sich aufgrund der hohen Präzision der Schätzung nicht.

## 6. Diskussion

Die Ergebnisse der beiden gezeigten Netze lassen sich anhand ihrer spezifischen Netzeigenschaften erklären und daraus Schlüsse für zukünftige Anwendungen ableiten. Die Resultate der restlichen Netzvarianten erhärten diese Hypothesen.

So ist zunächst festzustellen, dass einschichtige NN selbst bei hoher Neuronenzahl (40) für die vorliegende Regressionsaufgabe ungeeignet sind. Auch bei mehreren Hidden Layers ist eine Mindestanzahl an Neuronen notwendig, da eine Netzvariante mit insgesamt 13 Neuronen in drei Schichten deutlich schlechtere Ergebnisse als die zuvor gezeigte Netzvariante B erzeugt. Variante A dagegen besitzt einige Kanten, deren Gewicht auf Werte nahe 0 reduziert wurden. Von einer noch höheren Neuronenzahl ist daher keine weitere Verbesserung zu erwarten.

Bezüglich des Trainingsalgorithmus lässt sich festhalten, dass die besten Ergebnisse von Netzvarianten mit Bayesian Regularization erzielt wurden. Exemplarisch hierfür stehen die Ergebnisse in Bild 6, wo der BR-Algorithmus unabhängig von der Aktivierungsfunktion




Bild 6: Vergleich der Trainingsalgorithmen (LM, BR) und Aktivierungsfunktionen (Sigmoid, ReLU) an einer Netzvariante mit 3 Hidden Layers mit 16, 8 und 4 Neuronen anhand des MSE (niedriger ist besser)

bessere Resultate erzielt als der LM-Algorithmus. Dies kann zunächst mit einer stärkeren Generalisierung erklärt werden. Eine weitere mögliche Erklärung ist, dass – anders als beim LM-Algorithmus – keine Daten für die Validierung zurückgehalten werden müssen und daher mehr Trainingsdaten zur Verfügung stehen. Dies macht außerdem die Konfiguration von Netzen mit BR-Algorithmus weniger zeitaufwendig, da sich die Frage nach der optimalen Aufteilung zwischen Trainings- und Validierungsdaten gar nicht erst stellt.

Eine in jedem Fall optimale Aktivierungsfunktion lässt sich aufgrund der gewonnenen Daten nicht angeben. Bei Netzen mit drei Schichten und wenigen Neuronen liefert die Sigmoidfunktion bessere Ergebnisse, wie aus Bild 6 hervorgeht. Bei zweischichtigen Netzen mit mehr Neuronen je Schicht ist die ReLU-Aktivierung erfolgreicher. Diese Aufteilung lässt sich auch an den beiden vorgestellten optimalen Netzen beobachten. Dies legt nahe, dass die komplexer geformte Sigmoidfunktion zusätzliche Freiheitsgrade einbringt, die bei geringer Neuronenzahl eher notwendig sind. Zwei weitere Beobachtungen lassen sich auf die Wahl der Aktivierungsfunktion zurückführen: Geringe negative Nachweiszeitpunkte erzeugen nur solche Netze, die eine Sigmoidfunktion verwenden. Erklären lässt sich das damit, dass diese – anders als ReLUs – an der Nullstelle glatt sind. Eine weitere Beobachtung betrifft die Geschwindigkeit und Stabilität des Trainingsprozesses, welche beide mit ReLUs höher sind als mit Sigmoidfunktionen. Ausschlaggebend hierfür ist die Einfachheit der ReLU-Funktion, insbesondere ihre konstante Ableitung.

Die untersuchten NN-Varianten wurden mehrmals trainiert und verglichen, um den Einfluss zufälliger Größen – z.B. der Reihenfolge der Trainingsdaten – zu eliminieren. Dabei zeigte




Bild 7: Vergleich mehrerer Trainingsdatensätze an einer Netzvariante mit 2 Hidden Layers mit 40 und 16 Neuronen, BR und ReLU anhand des MSE (niedriger ist besser)

sich, dass Netzvarianten mit sigmoidaler Aktivierungsfunktion dazu neigen, in manchen Wiederholungen Netze mit sehr hohem Fehler (bis zu Faktor 358 über dem niedrigsten Wert) zu erzeugen. Netze mit ReLUs lieferten eher reproduzierbar gute Ergebnisse, fanden also öfter das (mutmaßlich globale) Optimum. Eine mögliche Erklärung hierfür ist die Unbeschränktheit dieser Aktivierungsfunktion.

Der Vergleich verschiedener Trainingsdatensätze zeigt, dass automatisiert im Parameterraum verteilte Datenpunkte bessere Trainingsergebnisse erzielen als manuell ausgewählte Parameterstufenkombinationen, siehe Bild 7. Dies zeigt die Vorteile eines Algorithmus, der den Parameterraum möglichst gleichmäßig auszufüllen versucht, auf die Qualität der Trainingsdaten. Die klassischerweise beobachtbare Verbesserung der Ergebnisse mit einer größeren Menge an Trainingsdaten zeigte sich auch in dieser Untersuchung; für zukünftige Betrachtungen wird daher mindestens eine mittlere vierstellige Anzahl an Datenpunkten für diese Anzahl an Parametern (8) empfohlen.

## 7. Zusammenfassung & Ausblick

In diesem Beitrag wurden künstliche neuronale Netze untersucht, die zum Einsatz im Rahmen eines Algorithmus zur Ermittlung eines optimalen Testplans bestimmt sind. Die neuronalen Netze sollen diesen Algorithmus beschleunigen, indem sie die nachweisbare Lebensdauer eines Zuverlässigkeitstests schätzen und eine Vorauswahl erfolgversprechender Testkonfigurationen erlauben. Es konnte gezeigt werden, dass – bei entsprechender Wahl der Netzparameter – eine solche Schätzung mit einer Genauigkeit von bis zu einem Prozent möglich ist. In der Folge konnte in einem Beispielszenario die Rechenzeit deutlich verringert werden. Das Grundmodell eines feedforward-Netzes zur Regression der nachweisbaren Lebensdauer aus nominell acht Eingangsgrößen wurde dabei in mehreren Netzparametern variiert, einem überwachten Lernprozess unterzogen und anschließend verglichen. Es konnte dargestellt werden, welche Netzgröße und Parameterwahl notwendig ist, um ein neuronales Netz zu erhalten, welches die nachweisbare Lebensdauer mit hoher Genauigkeit schätzt.

Diese Erkenntnisse legen den Grundstein für eine rechenzeiteffiziente Testplanung ohne die Notwendigkeit einer aufwendigen MC-Simulation. Der Vergleich vieler Testkonfigurationen auf ihre Eignung als Testplan wird innerhalb kürzester Zeit möglich. Dies erhöht einerseits die Praxistauglichkeit entsprechender Verfahren zur optimalen Testplanung in der industriellen Praxis. Andererseits kann darauf aufbauend die Erweiterung des Anwendungsbereichs – beispielsweise auf zusätzliche Lastniveaus, zensierte Ausfalldaten, andere Schätzverfahren oder alternative Testarten – erforscht werden.

## 8. Literaturangaben

- [1] Bertsche, B. und Lechner, G.: Zuverlässigkeit im Fahrzeug- und Maschinenbau: Ermittlung von Bauteil- und System-Zuverlässigkeiten. Berlin, Heidelberg: Springer 2004.
- [2] Dazer, M. et al.: Optimal planning of reliability life tests considering prior knowledge. RAMS 2018.
- [3] Herzig, T. et al.: Cost- and Time-Effective Planning of Accelerated Reliability Demonstration Tests – A New Approach of Comparing the Expenditure of Success Run and End-of-Life Tests. RAMS 2019.
- [4] Nelson, W. B.: Accelerated Testing: Statistical Models, Test Plans, and Data Analysis. Hoboken: John Wiley & Sons Inc. 2009.
- [5] Srivastava, P. W.: Optimum Accelerated Life Testing Models with Time-Varying Stresses. Singapore: World Scientific Publishing Co. 2017.
- [6] Modarres, M. et al.: Probabilistic Physics of Failure Approach to Reliability: Modeling, Accelerated Testing, Prognosis and Reliability Assessment. Hoboken: John Wiley & Sons Inc. 2017.
- [7] Bishop, C. M.: Pattern Recognition and Machine Learning. New York: Springer 2006.
- [8] Aggarwal, C. C.: Neural Networks and Deep Learning: A Textbook. Cham: Springer International Publishing, 2018.
- [9] Ripley, B. D.: Pattern Recognition and Neural Networks. Cambridge, UK: Cambridge University Press, 2005.
- [10] MacKay, D. J. C.: Bayesian Interpolation. Neural Computation, 1992.4, S. 415–447
- [11] Foresee, F. D. und Hagan, M. T.: Gauss-Newton Approximation to Bayesian Learning. Proc. of the 1997 International Conference on Neural Networks, 1997, S. 1930–1935
- [12] Levenberg, K.: A Method for the Solution of Certain Non-Linear Problems in Least Squares. Quarterly of Applied Mathematics, Vol. 2.2, 1944, S. 164–168
- [13] Marquardt, D. W.: An Algorithm for Least-Squares Estimation of Nonlinear Parameters. Journal of the Society for Industrial and Applied Mathematics, 1962.2, S. 431–441

## **Erstellung eines digitalen Zwillings für die additive Fertigung mittels KI**

### **Problemanalyse der additiven Fertigung zur Vermeidung von Druckfehlern**

**Sören Wenzel**, M.Sc., Dr.-Ing. **Elena Slomski-Vetter**,  
Prof. Dr.-Ing. **Tobias Melz**, Fachgebiet Systemzuverlässigkeit,  
Adaptronik und Maschinenakustik SAM,  
Technische Universität Darmstadt

#### **Kurzfassung**

In der additiven Fertigung, auch häufig als 3D-Druck bezeichnet, gibt es eine hohe Fehlerzahl, die zu einem hohen Ausschuss der gedruckten Teile führt. Dies liegt u. a. an der Vielzahl der einzustellenden Parameter, die der Bediener aufgrund seiner erworbenen Erfahrungen richtig einzustellen weiß. Die Zuverlässigkeit des Prozesses und der gedruckten Bauteile unabhängig vom Bediener ist somit nicht gewährleistet. Um den Ausschuss zu minimieren und die Zuverlässigkeit additiv gefertigter Bauteile sicherzustellen, wird erheblicher Aufwand in die Einstellung von Toleranzen, in die Fertigung der Druckerkomponenten und in die Integration von Sensorik investiert.

In der vorliegenden Arbeit werden die Möglichkeiten erörtert, mithilfe von Testdrucken und Kenntnissen aus der Literatur einen digitalen Zwilling eines 3D-Druckers zu erstellen. Anhand dieses Zwillings sollen Fehlerwahrscheinlichkeiten des Druckers vorhergesagt werden. Der digitale Zwilling wird mithilfe von verschiedenen Techniken wie NeuroEvolution of Augmenting Topologies (NEAT) kombiniert mit Techniken wie Kriging erstellt. Bei NEAT wird ein neuronales Netz trainiert, das sich selbst im Betrieb durch Hinzufügen von neuen Pfaden und Knoten erweitert. Kriging beschreibt die Annäherung von Werten an unbekannte Punkte durch Interpolation der benachbarten Punkte und Abschätzung der Veränderung der Werte, abhängig vom Abstand der Punkte. Mit weiteren Testdrucken an anderen 3D-Druckern kann das vortrainierte Netz schnell auf das Verhalten von anderen 3D-Druckern erweitert werden.

Der hohe Innovationsgrad besteht in der Entwicklung eines digitalen Zwillings, durch den das bisherige Lernen durch eine systematische Fehleranalyse und einen integrierten numerischen Lernprozess ersetzt wird. So wird die additive Fertigung mit wechselnden Materialien bei verkürzten Rüstzeiten und unter verringertem Personalaufwand möglich.

## 1. Einleitung

Die Herstellung von Kunststoffteilen mittels 3D-Druck ist auf dem Weg sich in der Massenproduktion durchzusetzen [1]. Einzelne Anwendungsfälle, wie beispielsweise die Produktion von Schuhen [2] oder Elektrodenmaterial [3] werden heute schon in Serie in 3D-Druck hergestellt. Der große Vorteil einer Massenprodukten aus dem 3D-Druck gegenüber der konventionellen Fertigung ist die größere Variabilität und die Individualität der Produkte [4, 5]. Dadurch können neue Einnahmequellen erschlossen werden, indem maßgeschneiderte Produkte hergestellt werden können [1].

Fused Deposit Modeling (FDM) ist ein günstiger und weit verbreiteter 3D-Druck-Prozess [6, 7], der in den frühen 90er Jahren entwickelt wurde und dessen Hauptverarbeitungsmaterial Polymere sind [8]. Bei FDM wird das Polymere erhitzt, bis es einen halbflüssigen Zustand erreicht. Dann wird es aus einer Düse herausgepresst, kühlt ab und wird kurz danach fest. So können schichtweise Produkte erstellt werden [9]. Der Druckprozess ist dabei von Druckparametern abhängig, die unter anderem die Anzahl und Eigenschaften der Schichten, Geschwindigkeiten und Temperaturen festlegen.

Um den FDM-Prozess ökonomisch in der Massenfertigung nutzen zu können, müssen die Maschinenkosten und die Personalkosten reduziert werden [10]. Mit dieser Arbeit wird das Ziel verfolgt, die Druckparameter automatisch vorgeben zu können, was Personalkosten einspart. Im Fall aktuell verwendeter 3D-Drucker werden die Druckparameter häufig vom Hersteller vorgegeben [11]. Dabei wird vom Hersteller auch erwähnt, dass das Druckergebnis noch verbessert werden kann. Außerdem können sich verschiedene Optimierungsziele bei der Fertigung von 3D-gedruckten Teilen widersprechen, wie Druckgeschwindigkeit, Festigkeit und Optik [12]. So kann der Hersteller unmöglich die besten Druckparameter vorgeben. Es kann sein, dass nach einer Veränderung des 3D-Druckers Druckfehler auftreten, wenn die Druckparameter nicht angepasst werden. Dies kann beispielsweise durch eine Reparatur oder mit dem Druck eines geänderten Materials passieren. In so einem Fall müssen die Druckparameter vom Bediener optimiert werden [13], mit entsprechenden Personal- und Maschinenstunden.

Im Folgenden wird untersucht, wie das Problem der Vermeidung von Druckfehlern anhand von geeigneten Parametern beschaffen ist und welche Methoden der Modellbildung genutzt werden können, um einen digitalen Zwilling zu erstellen.



## 2. Problemanalyse der Erstellung eines digitalen Zwillings zur Vermeidung von Druckfehlern in der additiven Fertigung

Im Rahmen dieser Arbeit bedeuten Druckfehler in der additiven Fertigung, dass der Druckprozess abgebrochen werden muss, oder dass optische Makel am 3D-gedruckten Produkt vorhanden sind. Den Einfluss, den ein Parameter auf einen Fehler hat, wird Totaleffekt genannt. Der Totaleffekt besteht aus Wechselwirkungseffekten und dem Haupteffekt. Der Haupteffekt ist der Einfluss des Parameters, der nur von dem Parameter selbst abhängig ist. Wechselwirkungseffekte sind auch von anderen Parametern abhängig. Die Ordnung einer Wechselwirkung gibt an, von wie vielen anderen Parametern der Einfluss noch abhängig ist.

Es existieren eine Vielzahl von Leitfäden, die bei Druckfehlern schnelle Hilfe durch Änderung von Parameter versprechen [14 bis 17]. Beispielsweise empfiehlt Richter [17] bei 40 von insgesamt 45 verschiedenen Druckfehler die Änderung von 18 verschiedenen Parametern. Die weiteren fünf Probleme sollen durch eine Wartung oder Reparatur behoben werden. Die Drucktemperatur soll auf 22 Druckfehler einen Einfluss haben, während die Druckgeschwindigkeit auf 18 Druckfehler einen Einfluss haben soll. Insgesamt sollen 10 Parameter einen Einfluss auf jeweils mehr als 5 Druckfehler haben. Alle Druckfehler sollen sich durch eine Änderung von Parametern in eine Richtung zumindest verbessern lassen können [14 bis 17]. Daher wird die Annahme getroffen, dass die Effekte von Parametern auf Druckfehlern monoton steigend oder fallend sind. Aus der Literatur sind auch Wechselwirkungen zwischen Druckparametern bekannt [12, 18 bis 21]. Die Effekte von Parametern auf Druckfehler, die bisher nicht untersucht worden sind, können eine relevante Rolle spielen. Diese Zusammenhänge machen die automatisierte Einstellung von Druckparametern für die Vermeidung von Druckfehlern sehr schwierig. Beispielsweise lassen sich für das Programm Slic3r in der aktuellen Version 1.3.0 mithilfe der Anleitung [22] insgesamt 56 Parameter ausmachen, die einen Einfluss auf Druckfehler haben könnten. Um die Einflüsse der Druckparameter auf die Druckfehler zu untersuchen, müssen Produkte mit einem 3D-Drucker gedruckt und bewertet werden. Ein Produkt wird je nach Größe des Objekts und der Auswahl der Parameter in 10 Minuten bis 1 Stunde gefertigt. Das macht die Erzeugung einer statistisch belastbaren Menge an Versuchen sehr zeitaufwändig.

Für die Vermeidung von Druckfehlern ist die genaue Kenntnis der Parameter über den gesamten Versuchsraum nicht erforderlich. Ausreichend ist die Erkennung der Grenzen der Bereiche, in denen ohne Fehler gedruckt werden kann. Schließlich sollen die Parameter so verändert werden, dass ohne Druckfehler gedruckt wird. Sollte sich die Zielvorgabe ändern und es wer-

den nicht mehr Fehler vermieden, sondern es sollen bestimmte Eigenschaften, wie Druckgeschwindigkeit oder Festigkeit beeinflusst werden, dann sollten die Bereiche untersucht werden, in denen keine Fehler auftreten.

### 3. Statistische Versuchsplanung

Die statistische Versuchsplanung ist die Grundlage für den digitalen Zwilling zur Vorhersage von Druckfehlern, um Druckfehler zu vermeiden. Im Folgenden werden die Methoden kurz vorgestellt und für das vorliegende Anwendungsgebiet sinnvolle Methoden ausgewählt.

#### Faktorielle Pläne

Bei einem zweistufigen vollfaktoriellen Plan werden für die Versuche alle minimalen und maximalen Parameterstufen kombiniert. Wenn man sich den Parameterraum als multidimensionalen Würfel vorstellt, bei dem jede Dimension einem Parameter entspricht, werden alle Versuche in den Ecken durchgeführt, da alle Parameter so gewählt sind, dass sie in eine Richtung begrenzt sind. Um einen teilfaktoriellen Plan zu erstellen, werden beliebig oft aus dem zweistufigen vollfaktoriellen Plan die Hälfte der Punkte nach einer mathematischen Bedingung gelöscht. Die Auflösung des Plans bestimmt sich durch die Wechselwirkungseffekte, die von den Haupteffekten nicht mehr unterschieden werden können. Wenn es beispielsweise Wechselwirkungseffekte 2. Ordnung gibt, die mit einem Haupteffekt überlagert sind, dann hat der Plan die Auflösung 3. Faktorielle Pläne lassen sich durch Mittelpunkte auf Flächen, Kanten und im Volumen ergänzen [23]. Trotzdem werden bei den faktoriellen Plänen vor allem Extrempunkte untersucht, da Punkte auf Flächen und Kanten sich ausschließlich auf dem Rand des Versuchsraums befinden.

Faktorielle Pläne können noch schneller untersucht werden, wenn sie parallel ausgeführt werden. Dazu werden die Parameter in Gruppen aufgeteilt und für jede Gruppe wird ein eigener faktorieller Versuchsplan aufgestellt. Diese Versuchspläne werden dann gleichzeitig durchgeführt. So werden nur sehr wenige Experimente durchgeführt und die relevanten Parameter können fast immer bestimmt werden [24].

Nach der Grafik von looss et al. [25] in Bild 1 sollte für die vorliegende Anwendung ein teilfaktorieller Versuchsplan durchgeführt werden mit Auflösung (engl. Resolution, kurz R) 3 oder 4, da für die Parameter und die Fehler vor allem monotone Zusammenhänge mit Wechselwirkungen vermutet werden (engl. Monotonic with interactions).

Gegen die Verwendung von faktoriellen Plänen spricht, dass vor allem die Ränder des Parameterraums untersucht werden. Ein digitaler Zwilling wird anhand der Daten erstellt und dieser soll den kompletten Versuchsraum beschreiben können.

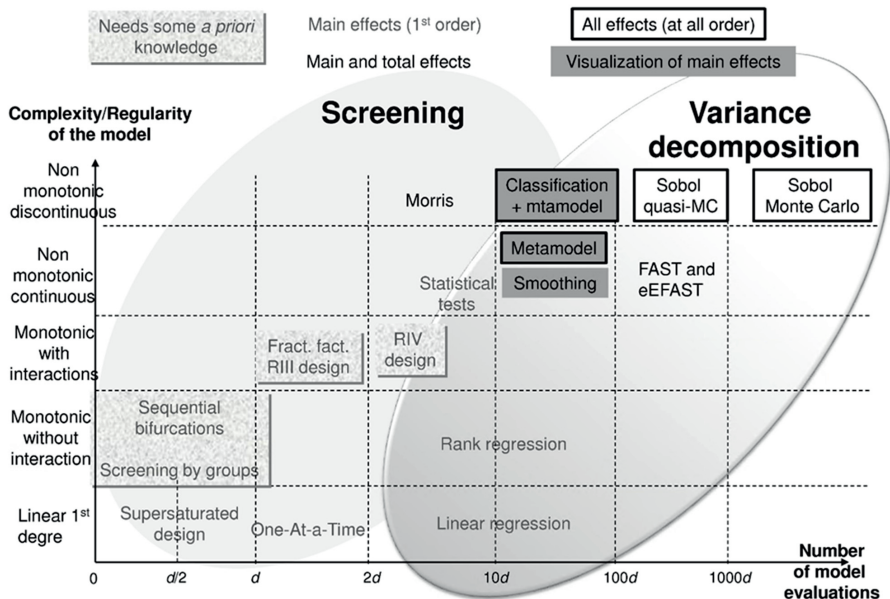


Bild 1: Grafische Übersicht von Methoden der Sensitivitätsanalysen aus [25].

### Latin Hypercube Sampling (LHS)

Gute Ergebnisse zur Erstellung eines digitalen Zwillings können mit Latin Hypercube Sampling (LHS) erzielt werden [26 bis 29]. LHS ist ein pseudozufälliger raumfüllender Versuchsplan. Beim LHS werden die Werte der Parameter in gleich große Intervalle aufgeteilt. In vordefinierten Intervallen von jedem Parameter wird genau ein Versuch durchgeführt [30]. Die Parameterintervalle werden so kombiniert, dass ein annähernd orthogonaler Versuchsplan erstellt wird [31]. Ein orthogonaler Versuchsplan hat die Eigenschaft, dass die Parameterstufen nicht miteinander korrelieren. Mit einem LHS lässt sich der Versuchsraum für die Vermeidung von Druckfehlern effizienter als mit einem faktoriellen Plan untersuchen, da nicht der komplette Versuchsraum bekannt sein muss, sondern die Bereiche, in denen fehlerfrei gedruckt werden kann.

### Adaptives Sampling

Um die Versuchsergebnisse des LHS zu verbessern gibt es die Möglichkeit den Versuchsraum selektiv genauer abzutasten. Dies geschieht beim adaptiven Sampling [27, 29, 32, 33], dargestellt in Bild 2. Hier wird zwischen den beiden Schritten der *Exploration* und der *Exploitation* unterschieden. Die Exploration beschreibt die allgemeine Erkundung des Versuchsraums anhand eines beliebigen Versuchsplan. Der zweite Schritt, die Exploitation beschreibt die selektive Untersuchung des Versuchsraums. Dabei werden mit einer Optimierung im Modell Parameterkombinationen im Versuchsraum ausfindig gemacht. Die Optimierung kann beispielsweise im Modell nach Ungenauigkeit oder Volatilität suchen [27].




Bild 2: Flussdiagramm zum Ablauf von adaptiven Sampling.

Von den vorgestellten Methoden wird der adaptive Ansatz zur Erstellung eines digitalen Zwillings ausgewählt. Für die Vermeidung von Druckfehlern sind vor allem die Übergänge zwischen Druckfehlern und den Bereichen ohne Druckfehler wichtig, um die Grenzen des fehlerfreien Druckbereiches zu finden. Diese können innerhalb des adaptiven Ansatzes gezielt gesucht und untersucht werden.

### 3. Modellbildung für den digitalen Zwilling

Zur Modellbildung für den digitalen Zwilling bieten sich verschiedene räumliche Analysemethoden an, die aus einzelnen gemessenen Punkten andere Punkte interpolieren können [34]. Das sind zum Beispiel inverse Distanzwichtung oder die Methoden des Kriging, der Regression oder der künstlichen Intelligenz. Einen Überblick über die Methoden der Modellbildung, die in dieser Arbeit diskutiert werden, gibt Bild 3.

## Inverse Distanzwichtung und Kriging

Die inverse Distanzwichtung und das Kriging sind Methoden, bei denen unbekannte Punkte aus gewichteten Summen gebildet werden. Bei der inversen Distanzwichtung entsprechen die Gewichte der inversen Distanz. Diese Methode ist sehr einfach und stellt keine Anforderungen an den Bediener. Sie kann gut automatisiert werden.

Beim Kriging, auch als Gaußprozess-Regression bezeichnet, werden die Gewichte durch die räumliche Varianz gebildet. Die räumliche Varianz wird bestimmt, indem die räumlichen Abstände zwischen Punkten mit den Unterschieden in den Werten der Punkte korreliert werden. Es existieren verschiedene Varianten des Kriging, mit denen die Modellbildung variiert wird, um für unterschiedliche Anwendungsfälle anwendbar zu sein. Für die Anwendung in der Fehlervermeidung eignet sich das universelle Kriging. Beim universellen Kriging wird ein globales Modell anhand einer polynominalen Regression ermittelt. Das Modell wird mithilfe von Kriging verbessert, dass an den Unterschieden der gemessenen Punkte vom globalen Modell ausgeführt wird [34]. Für die Modellbildung im adaptiven Sampling ist diese Methode besonders geeignet [35]. Für die Vorhersage von Druckfehlern können mit dem globalen Modell die Effekte abgelesen werden, während die Interpolation durch das zusätzliche Kriging sehr genau ist. In einer Anwendung mit einer kleinen Stichprobe wurde einfaches Kriging schon erfolgreich an 3D-Druckern ausgeführt [36]. Der Unterschied zum universellen Kriging liegt in dem globalen Modell, das beim einfachen Kriging nur der Mittelwert aller Punkte ist. Für die Erstellung des digitalen Zwillings während dem adaptiven Sampling sollte das universelle Kriging angewendet werden, da die Interpolation sehr gut funktioniert.

## Regression

Mit der linearen Regression lassen sich verschiedene Modelle zu unterschiedlichen Daten erstellen, wie lineare Modelle oder logit-Modelle. Mit den generalisierten Modellen lassen sich sehr viel mehr Modelle anhand von beliebigen Funktionen erstellen. Die Auswahl des Modells erfolgt am besten anhand der Modelldaten [37]. Da bei der adaptiven Versuchsplanung die Modellbildung schon erfolgt, bevor alle Daten ermittelt sind, ist es schwer vorherzusagen, welche Funktionen und Varianten der Regression die Daten gut wiedergeben. Zu der Anwendung des Modells während der genaueren Untersuchung kann eine lineare Regression mit quadratischen Termen und Wechselwirkungen verwendet werden [38]. Da sich so sehr viele Terme ergeben, sollte eine robuste Regression ausgeführt werden, bei der nichtrelevante Terme aus der Modellgleichung entfernt werden. Die Effekte der Parameter auf die Druckfehler können anhand der Modellgleichung abgelesen werden.

## Künstliche Neuronale Netze (KNN)

Die Funktionsweise der Künstlichen Neuronale Netze (KNN) ist von biologischen neuronalen Netzen abgeleitet. Die biologischen Netze bilden bei Menschen und Tieren die Nervensysteme und Gehirne [39]. Neuronale Netze bestehen aus vielen kleinen einfachen Rechenknoten, die parallel arbeiten [40]. Knoten können aus einer gewichteten Summe und einer Aktivierungsfunktion bestehen. Sie multiplizieren die Gewichte mit der *Aktivität* der verbundenen Knoten, bilden daraus eine Summe und berechnen mit der Aktivierungsfunktion daraus die eigene Aktivität, die dann weitergegeben wird. Die Gewichte der Knoten werden beim sogenannten Training anschließend variiert, um das gewünschte Verhalten des KNN zu erhalten. Die Aktivierungsfunktionen sind meist Funktionen, die die Eingabe auf den Wertebereich zwischen 0 und 1 projizieren [41]. Es gibt auch komplexere Knoten, die eine Art Gedächtnis haben [42] oder auch andere Funktionen erfüllen können [43].

Um KNN benutzen zu können, müssen diese trainiert werden. *Unüberwachtes Lernen* heißt, dass die KNN eigenständig Muster in einer Datenmenge finden müssen. Es ist unüberwacht, weil dem KNN keine Lösung vorgegeben wird, die es reproduzieren soll. Beim *überwachten Lernen* wird dem KNN mit den Daten auch eine Ausgabe vorgegeben. Die Gewichte der Knoten werden dann angepasst, sodass das KNN die Ausgabe zu den Daten möglichst reproduziert [44].

Die Architektur der KNN wird meist vor dem Training durch den Anwender bestimmt. Das beinhaltet die Art der Knoten, die Menge und die Vernetzung der Knoten. Außerdem müssen Eingabe und Ausgabe definiert werden. Eine Möglichkeit der Gestaltung der Architektur sind *feed-forward Netze*. Sie haben alle Knoten in Schichten angeordnet. Die Knoten einer Schicht sind mit allen Knoten der vorherigen Schicht verbunden. So können die Schichten nacheinander und die Werte der Knoten in den Schichten parallel berechnet werden. Die erste Schicht wird *Eingabeschicht* genannt und die letzte Schicht wird *Ausgabeschicht* genannt [44].

Ein Problem bei KNN ist *overfitting*. Das KNN lernt dann nicht allgemeingültig, sondern nur die Daten aus dem Training. Aus unbekannten Eingaben können dann keine Aussagen getroffen werden. Das Problem tritt vermehrt auf, wenn das KNN zu groß ist oder zu wenige Daten zum Trainieren vorhanden sind. Für die Fehlervermeidung werden die Daten experimentell mit hohem Zeitaufwand bestimmt, daher kann Overfitting ein Problem sein.

Ein Vorteil in der Verwendung von KNN ist die Möglichkeit vortrainierte KNN für die Anpassung an einen speziellen 3D-Drucker oder an ein anderes Druckverfahren zu verwenden. So kann das angelernte Wissen aus einem 3D-Drucker übertragen werden, ohne dass viele Daten erstellt werden müssen [45].

### NeuroEvolution of Augmenting Topologies (NEAT)

Eine andere Art die Architektur des Netzes aufzubauen, ist in NeuroEvolution of Augmenting Topologies (NEAT) umgesetzt. Hier wird nur die Eingabe- und Ausgabeschicht definiert. Die Knoten und Verbindungen zwischen den Schichten werden über einen evolutionären Optimierungsalgorithmus bestimmt. So wird die Architektur des KNN nicht größer als notwendig und ein Overfitting wird vermieden [46]. Ein weiterer Vorteil von NEAT ist die Erweiterbarkeit von Eingabe- und Ausgabeschichten. Dies ist bei NEAT deutlich einfacher durchzuführen, als bei anderen Netzen, da die Verbindungen in der Initialisierung nicht vorhanden sind. Für andere Netze müssen Gewichte und Knoten angepasst werden. Für NEAT müssen nur die Trainingsdaten angepasst werden.[47].

Die Methoden der Modellbildung sind in Bild 3 dargestellt. Für ein Modell der linearen Regression reicht ein teilfaktorieller Versuchsplan [25]. Für die generalisierte Regression, bei der beliebige Funktionen verwendet werden, wird ein raumfüllender Versuchsplan benötigt [37], genauso wie für die inverse Distanzwichtung und das Kriging [34]. Generell reproduzieren alle KNN die Informationen, mit denen sie trainiert wurden [48]. Scheinbar können mit anderen statistischen Methoden und weniger Daten bessere Ergebnisse erzielt werden. Die Stärke der KNN scheint sich bei sehr vielen Daten zu zeigen, wenn die Ergebnisse der statistischen Methoden durch mehr Daten nicht mehr verbessert werden können [29, 48, 49].

Für die Anwendung der Fehlervermeidung beim 3D-Druck bieten sich feed-forward Netze an, die mit überwachtem Lernen aus den Parametern die Fehler vorhersagen [50]. Allerdings werden von Zhou et al. [50] lediglich aus drei Parametern die Effekte auf einen Fehler vorhergesagt. Wenn eine Vielzahl von Fehler aus Parameter und Störgrößen vorhergesagt werden sollen, kann es zu einem Overfitting kommen. Eine Stärke von NEAT ist die Vermeidung von Overfitting und die Erstellung einer schlanken problembezogenen Architektur [47]. Daher ist NEAT für die Vorhersage von Druckfehlern geeignet.

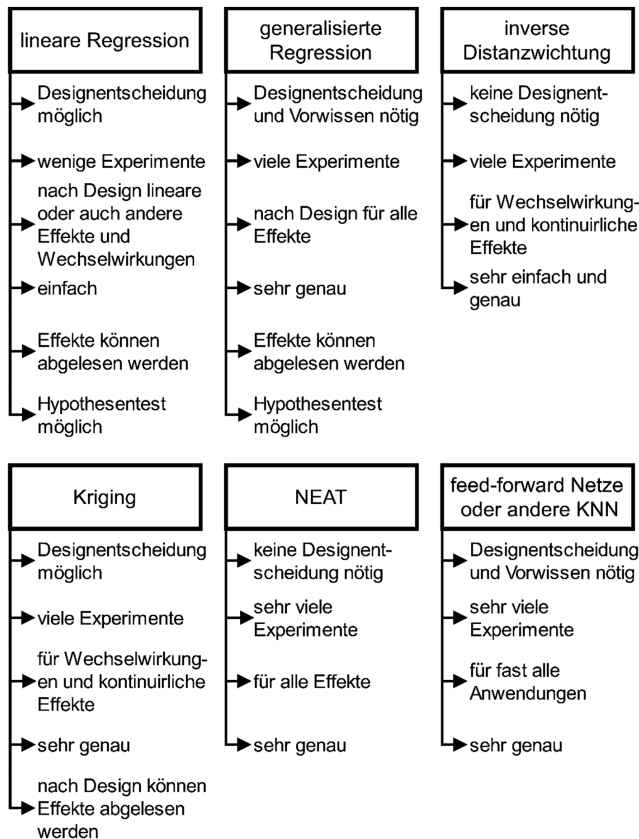


Bild 3: Übersichtsdiagramm zur Auswahl einer Methode zur Modellbildung.

#### 4. Fazit und Zusammenfassung

In dieser Arbeit werden verschiedene Methoden erörtert, mit denen eine Vermeidung von Druckfehlern anhand von Druckparametern und Störgrößen im FDM-Prozess ermöglicht werden soll. Durch das Verändern von Druckparametern können so Fehler vorhergesagt und kostspieliges Ausprobieren vermieden werden.



Bei der Vorhersage von Druckfehlern gibt es einige Parameter, die auf eine Vielzahl von Druckfehler einen Einfluss haben. Außerdem können Wechselwirkungen von Parametern beobachtet werden. Das macht die Auswahl und das richtige Einstellen für den Anwender der Druckparameter so schwer. Aus diesem Grund ist diese Aufgabe nicht automatisiert und wird heute noch von erfahrenen Experten übernommen. Um einen digitalen Zwilling zu erstellen, sollte ein adaptiver Ansatz in der Versuchsplanung wie in Bild 2 dargestellt, angewendet werden. Dieser besteht aus zwei Schritten. Während der Exploration, dem ersten Schritt wird der gesamte Versuchsraum erkundet. Das kann mit einem raumfüllenden Versuchsplan wie dem Latin-Hypercube-Sampling durchgeführt werden. Die Exploitation, der zweite Schritt dient der selektiven Untersuchung des Versuchsraums. Dabei wird ein digitaler Zwilling erstellt, der an den Rändern des fehlerfreien Bereichs gezielt verbessert wird. Diese Übergänge sind für die Vermeidung von Druckfehlern besonders wichtig.

Der digitale Zwilling für den zweiten Schritt der adaptiven Versuchsplanung kann mithilfe von Kriging erstellt werden. Beim Kriging muss nicht trainiert werden und es ist erwartungstreu. Das heißt, der Erwartungswert der Schätzung ist gleich dem wahren Wert. Es muss nicht mit sehr großen Fehlern in der Schätzung gerechnet werden, wie das etwa bei Künstlichen Neuronalen Netzen der Fall sein kann. Der digitale Zwilling kann auch mithilfe einer Regression erstellt werden. Allerdings sind hier viele Entscheidung in der statistischen Auswertung vom Bediener, und damit auch von der Erfahrung und den Kenntnissen des Bedieners abhängig. Ein einfaches Modell kann zwar mithilfe einer robusten Regression automatisch erstellt und verbessert werden, allerdings kann es zu großen Abweichungen kommen, da das Auftreten realer Druckfehler auch mit dem Modell übereinstimmen muss.

Mit Künstlichen Neuronalen Netzen kann der digitale Zwilling nach der adaptiven Versuchsplanung erstellt werden. Auch wenn sich feed-forward-Netze anbieten, sind mit NeuroEvolution of Augmenting Topologies bessere Ergebnisse zu erwarten. Ein Vorteil von Künstlichen Neuronalen Netzen zur Erstellung eines digitalen Zwillings wäre die einfache Übertragbarkeit von Erkenntnissen auf andere Drucker und Druckverfahren durch die Verwendung von vortrainierten Netzen.

## Literaturangaben

- [1] Jeff Kerns: 3D Printing Dives into Mass Production. The top FDM and SLA 3D-printing companies are looking to grab more market share from the injection-molding industry., 2017. <https://www.machinedesign.com/3d-printing-cad/article/21835689/3d-printing-dives-into-mass-production>, abgerufen am: 02.03.2021
- [2] Stan Horaczek: Nike hacked a 3D printer to make its new shoe for elite marathon runners, 2018. <https://www.popsci.com/nike-3d-printed-sneakers/>, abgerufen am: 02.03.2021
- [3] Foo, C. Y., Lim, H. N., Mahdi, M. A., Wahid, M. H. u. Huang, N. M.: Three-Dimensional Printed Electrode and Its Novel Applications in Electronic Devices. *Scientific reports* 8 (2018) 1, S. 7399
- [4] Shahrudin, N., Lee, T. C. u. Ramlan, R.: An Overview on 3D Printing Technology: Technological, Materials, and Applications. *Procedia Manufacturing* 35 (2019), S. 1286–1296
- [5] Ngo, T. D., Kashani, A., Imbalzano, G., Nguyen, K. T. u. Hui, D.: Additive manufacturing (3D printing): A review of materials, methods, applications and challenges. *Composites Part B: Engineering* 143 (2018), S. 172–196
- [6] Tofail, S. A., Koumoulos, E. P., Bandyopadhyay, A., Bose, S., O'Donoghue, L. u. Chritidis, C.: Additive manufacturing: scientific and technological challenges, market uptake and opportunities. *Materials Today* 21 (2018) 1, S. 22–37
- [7] Mwema, F. M. u. Akinlabi, E. T.: Basics of Fused Deposition Modelling (FDM). In: Mwema, F. M. u. Akinlabi, E. T. (Hrsg.): *Fused Deposition Modeling: Strategies for Quality Enhancement*. Cham: Springer International Publishing 2020, S. 1–15
- [8] Stansbury, J. W. u. Idacavage, M. J.: 3D printing with polymers: Challenges among expanding options and opportunities. *Dental materials: official publication of the Academy of Dental Materials* 32 (2016) 1, S. 54–64
- [9] Yap, Y. L., Tan, Y. S. E., Tan, H. K. J., Peh, Z. K., Low, X. Y., Yeong, W. Y., Tan, C. S. H. u. Laude, A.: 3D printed bio-models for medical applications. *Rapid Prototyping Journal* 23 (2017) 2, S. 227–235
- [10] Thomas, D.: Costs, Benefits, and Adoption of Additive Manufacturing: A Supply Chain Perspective. *The International journal, advanced manufacturing technology* 85 (2016) 5–8, S. 1857–1876
- [11] Layla Smid: Was macht Ultimaker Cura zur fortschrittlichsten 3D-Drucksoftware? <https://ultimaker.com/de/software/ultimaker-cura>, abgerufen am: 03.03.2021

- [12] Durão, L. F. C. S., Barkoczy, R., Zancul, E., Lee Ho, L. u. Bonnard, R.: Optimizing additive manufacturing parameters for the fused deposition modeling technology using a design of experiments. *Progress in Additive Manufacturing* 4 (2019) 3, S. 291–313
- [13] Bob George: Max volumetric speed. Filament Settings.  
[https://www.help.prusa3d.com/en/article/max-volumetric-speed\\_127176](https://www.help.prusa3d.com/en/article/max-volumetric-speed_127176), abgerufen am: 03.03.2021
- [14] Simplify3D: Print Quality Troubleshooting Guide, 2021. <https://www.simplify3d.com/support/print-quality-troubleshooting/>, abgerufen am: 03.03.2021
- [15] Prusa Research a.s.: Druckqualität-Fehlerbehebung, 2021.  
[https://help.prusa3d.com/de/category/druckqualitat-fehlerbehebung\\_225](https://help.prusa3d.com/de/category/druckqualitat-fehlerbehebung_225), abgerufen am: 03.03.2021
- [16] Just3DP: Typische Probleme beim 3D-Druck und ihre Lösung., 2016.  
<https://www.just3dp.com/blog/post/probleme-beim-3d-druck-und-ihre-loesung/>, abgerufen am: 03.03.2021
- [17] Marcel Richter: SOS-Druckfehler Übersicht, 2021. <https://einfach3ddruck.de/sos-druckfehler-schnell-und-effektiv-beheben/>, abgerufen am: 03.03.2021
- [18] Deshwal, S., Kumar, A. u. Chhabra, D.: Exercising hybrid statistical tools GA-RSM, GA-ANN and GA-ANFIS to optimize FDM process parameters for tensile strength improvement. *CIRP Journal of Manufacturing Science and Technology* 31 (2020), S. 189–199
- [19] Dey, A. u. Yodo, N.: A Systematic Survey of FDM Process Parameter Optimization and Their Influence on Part Characteristics. *Journal of Manufacturing and Materials Processing* 3 (2019) 3, S. 64
- [20] Pisarciuc, C.: Assessing the influence of significative parameters used in 3D Fused Filament Deposition. *IOP Conference Series: Materials Science and Engineering* 682 (2019), S. 12015
- [21] Snapp, K. L., Gongora, A. E. u. Brown, K. A.: Increasing Throughput in Fused Deposition Modeling by Modulating Bed Temperature. *Journal of Manufacturing Science and Engineering* (2021), S. 1–20
- [22] Gary Hodgson, Alessandro Ranellucci u. Jeff Moe: Slic3r Manual. <https://manual.slic3r.org/>, abgerufen am: 06.03.2021
- [23] Kleppmann, W.: Versuchsplanung. Produkte und Prozesse optimieren. Praxisreihe Qualitätswissen. München: Hanser 2016
- [24] Satterthwaite, F. E.: Random Balance Experimentation. *Technometrics* 1 (1959) 2, S. 111–137

- [25] Iooss, B. u. Lemaître, P.: A Review on Global Sensitivity Analysis Methods. In: Dellino, G. u. Meloni, C. (Hrsg.): *Uncertainty Management in Simulation-Optimization of Complex Systems. Operations Research/Computer Science Interfaces Series*. Boston, MA: Springer US 2015, S. 101–122
- [26] van Beers, W. u. Kleijnen, J.: Kriging Interpolation in Simulation: A Survey. *Proceedings of the 2004 Winter Simulation Conference*, 2004. IEEE 2004, S. 107–115
- [27] Kleijnen, J. P.: Kriging metamodeling in simulation: A review. *European Journal of Operational Research* 192 (2009) 3, S. 707–716
- [28] Østergård, T., Jensen, R. L. u. Maagaard, S. E.: A comparison of six metamodeling techniques applied to building performance simulations. *Applied Energy* 211 (2018), S. 89–103
- [29] Fuhg, J. N., Fau, A. u. Nackenhorst, U.: State-of-the-Art and Comparative Review of Adaptive Sampling Methods for Kriging. *Archives of Computational Methods in Engineering* (2020)
- [30] McKay, M. D., Beckman, R. J. u. Conover, W. J.: Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code. *Technometrics* 21 (1979) 2, S. 239–245
- [31] Ye, K. Q.: Orthogonal Column Latin Hypercubes and Their Application in Computer Experiments. *Journal of the American Statistical Association* 93 (1998) 444, S. 1430
- [32] Sacks, J., Welch, W. J., Mitchell, T. J. u. Wynn, H. P.: Design and Analysis of Computer Experiments. *Statistical Science* 4 (1989) 4, S. 409–423
- [33] Tenne, Y. u. Goh, C.-K. (Hrsg.): *Computational intelligence in expensive optimization problems. Adaptation, learning, and optimization*, Bd. 2. Berlin: Springer 2010
- [34] Paramasivam, C. R. u. Venkatramanan, S.: An Introduction to Various Spatial Analysis Techniques. In: *GIS and Geostatistical Techniques for Groundwater Science*. Elsevier 2019, S. 23–30
- [35] Amelie Fau, Jan N. Fuhg: Is Adaptive Sampling for Kriging a Good Idea? In: Francisco Chinesta, Rémi Abgrall, Olivier Allix, Michael Kaliske u. David Néron (Hrsg.): *ECCOMAS Congress 2020. VIII European Congress on Computational Methods in Applied Sciences and Engineering: proceedings*. 2020
- [36] Jothibabu, G. u. Gurunathan, S. K.: Surrogate Based Sensitivity Analysis of Part Strength due to Process Parameters in Fused Deposition Modelling. *Procedia Computer Science* 133 (2018), S. 772–778
- [37] Fahrmeir, L., Kneib, T. u. Lang, S.: *Regression*. Berlin, Heidelberg: Springer Berlin Heidelberg 2009

- [38] Rayegani, F. u. Onwubolu, G. C.: Fused deposition modelling (FDM) process parameter prediction and optimization using group method for data handling (GMDH) and differential evolution (DE). The International journal, advanced manufacturing technology 73 (2014) 1-4, S. 509–519
- [39] Kruse, R., Borgelt, C., Braune, C., Klawonn, F., Moewes, C. u. Steinbrecher, M.: Computational intelligence. Eine methodische Einführung in künstliche neuronale Netze, evolutionäre Algorithmen, Fuzzy-Systeme und Bayes-Netze. Lehrbuch. Wiesbaden: Springer Vieweg 2015
- [40] DARPA neural network study. Neuronale Netze. Studie des DARPA (U.S. Defense Advanced Research Project Agency). Fairfax: AFCEA International Press 1988
- [41] Warren S. Sarle: Neural Network FAQ. comp.ai.neural-nets famous asked questions, 2002. <ftp://ftp.sas.com/pub/neural/FAQ.html>, abgerufen am: 02.03.2021
- [42] Hochreiter, S. u. Schmidhuber, J.: Long short-term memory. Neural computation 9 (1997) 8, S. 1735–1780
- [43] Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. u. Lang, K. J.: Phoneme recognition using time-delay neural networks. IEEE Transactions on Acoustics, Speech, and Signal Processing 37 (1989) 3, S. 328–339
- [44] Haykin, S. S.: Neural networks. A comprehensive foundation. New York, NY: Macmillan 1994
- [45] Application of Pretrained Deep Neural Networks to Large Vocabulary Speech Recognition. 2012
- [46] Stanley, K. O. u. Miikkulainen, R.: Evolving neural networks through augmenting topologies. Evolutionary computation 10 (2002) 2, S. 99–127
- [47] Stanley, K. O.: Efficient Evolution of Neural Networks through Complexification
- [48] Paliwal, M. u. Kumar, U. A.: Neural networks and statistical techniques: A review of applications. Expert Systems with Applications 36 (2009) 1, S. 2–17
- [49] Makridakis, S., Spiliotis, E. u. Assimakopoulos, V.: Statistical and Machine Learning forecasting methods: Concerns and ways forward. PloS one 13 (2018) 3, e0194889
- [50] Zhou, X., Hsieh, S.-J. u. Wang, J.-C.: Accelerating extrusion-based additive manufacturing optimization processes with surrogate-based multi-fidelity models. The International journal, advanced manufacturing technology 103 (2019) 9-12, S. 4071–4083



# Ableitung von Grenzwerten für die Tauschaufbereitung auf Basis von Zuverlässigkeitsanalysen

M.Sc. **Andreas Kroner**,  
Mercedes-Benz AG, Stuttgart;  
Prof. Dr.-Ing. **Bernd Bertsche**,  
Institut für Maschinenelemente, Universität Stuttgart

## Kurzfassung

Die Refabrikation bietet eine wirtschaftliche und zugleich umweltschonende Möglichkeit zur Bereitstellung von Ersatzteilen. Hierfür durchlaufen Komponenten einen industriellen Aufbereitungsprozess. Innerhalb der Refabrikation besitzt der Prozessschritt „Prüfen“ eine besondere Bedeutung. Hierfür werden geeignete Prüfkriterien und Grenzwerte benötigt, um den Zustand der Komponenten zu bewerten und für ein zweites Produktleben freizugeben. Bei der Einführung von neuen Produkten, wie z.B. Automatikgetrieben in das Aufbereitungsportfolio werden zu Beginn kostenintensive Komponenten wie die Vollintegrierte Getriebesteuerung (VGS), welche die gesamte Sensorik und das Getriebesteuergerät (ECU) beinhaltet, auf eine mögliche Wiederverwendung untersucht. Durch die kurzen Entwicklungszyklen und damit verbundenen kurzen Versuchszeiträume zur Absicherung der entwickelten Komponenten neigen Produkte zu einer Überdimensionierung, um die geforderte Lebensdauer mit den zur Verfügung stehenden Ressourcen, (bsph. Püfstandskapazitäten und Prüfzeiten) zu erreichen. Darüber hinaus zeigen die angewendeten Prüfprofile abweichend zum Realbetrieb eine raffende Wirkung. Daher bietet die Analyse von im Feld ausgefallenen Komponenten auch außerhalb der Garantiezeit eine Möglichkeit, das volle Potential der Komponenten im Rahmen eines zweiten Produktlebens auszunutzen und diese Erkenntnisse für die Entwicklung neuer Prüfkriterien und das Ableiten von Grenzwerte für die Refabrikation zu nutzen.

## Motivation

In den meisten technischen Anwendungen ist die Lebensdauer vieler Komponenten durch Alterungsmechanismen begrenzt [1]. Dabei hängt die Alterung, z.B. der Verschleiß, hauptsächlich von der Konstruktion und dem Aufbau der Bauteile, den Betriebsbedingungen und den Umgebungsparametern ab [2]. Dies gilt insbesondere für Fahrzeuggetriebe, da die Nutzungsprofile aufgrund des weltweiten Einsatzes von Fahrzeugen stark variieren. Dabei wird die Be-

lastung auf die jeweiligen Komponenten durch den Fahrer, die Fahrumgebung und das Fahrzeug selbst bestimmt. Im Falle eines Fehlereintritts innerhalb des Gesamtsystems Getriebe führt dieser im Allgemeinen zum Ausfall des Aggregates. Es besteht dann die Möglichkeit, das vorhandene Aggregat mithilfe der Reparatur, Grundüberholung oder der Refabrikation (engl. Remanufacturing) wieder in einen funktionsfähigen Zustand zu überführen oder das gesamte Aggregat durch ein Neuteil zu ersetzen. Hierbei unterscheidet sich jedoch der Aufwand und das Ziel der Maßnahmen deutlich. So hat die Reparatur das Ziel, den Fehler, der zum Ausfall geführt hat, zu lokalisieren und zu beheben [3]. Die Grundüberholung verfolgt das Ziel, den Fehler zu beheben und dabei alle Verschleißteile zu ersetzen und strebt eine längere Nutzungsdauer des Produktes an [3]. Im Gegensatz hierzu hat die Refabrikation das Ziel, das defekte Aggregat in Standardisierten Prozessschritten in einen neuwertigen Produktzustand zu überführen, der gleichwertige Qualitätssicherungsmaßnahmen wie der Neuteilprozess besitzt [4]. Die Refabrikation von Komponenten und gesamten Aggregaten bietet eine kostengünstige und ökologische Alternative zu den üblichen Grundüberholungs- und Reparaturansätzen. Ziel ist es dabei, durch die Wiederverwendung von Komponenten Ressourcen zu sparen und durch einen Industrieprozess qualitativ gleichwertige Produkte zu dem jeweiligen Neuteil bereitzustellen. Die Einsparung an Energie und Arbeitsschritten, gerade in der Formgebung durch energieintensive Fertigungsverfahren bsph. das Gießen und Zerspanen der Gehäuse, kann dem Kunden dabei durch einen Kostenvorteil weitergegeben werden [1]. Weiterhin bietet die Refabrikation den Vorteil einer hohen Qualitätssicherung im Vergleich zu einer Generalüberholung oder der klassischen Reparatur. Aus diesem Grund kann bei aufbereiteten Produkten eine Gewährleistung auf das gesamte Produkt/Aggregat gegeben werden. Im Gegensatz dazu wird bei einer Reparatur meist nur eine Gewährleistung auf den Reparaturumfang gegeben. Innerhalb des Remanufacturing-Prozesses werden defekte Produkte (sog. "Cores" [1]) in Zusammenarbeit mit Werkstätten und Händlern aus dem Feld gesammelt und zu zentralen Aufbereitungsstandorten gesandt. Um dem Kunden schnellstmöglich ein Ersatzteil anbieten zu können, wird das defekte Getriebe auf Basis eines Pfandsystems durch ein instandgesetztes Getriebe, aus dem Refabrikationsprozesses ersetzt. Dadurch kommen die Cores in einem unbekannten technischen Zustand an einem der Aufbereitungswerke an und durchlaufen die wesentlichen Prozessschritte: Demontage, Reinigung, Prüfung (auf Bauteil oder Komponentenebene zur Zustandsbestimmung), Aufbereitung, und Montage. Um die Qualität zu sichern kann optional eine Produktprüfung, eine sogenannte End-of-Line Prüfung, implementiert werden [1]. Der systematische Ablauf des Refabrikationsprozesses ist in Bild 1, ohne eine End-of-Line Prüfung, dargestellt.



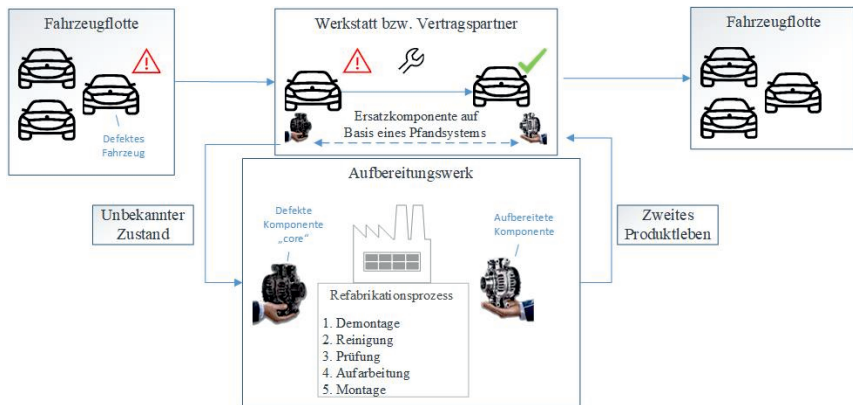


Bild 1: Systematischer Refabrikationsprozess eingebunden in den Tauschkreislauf defekter und aufbereiteter Aggregate [5].

Innerhalb des Prozessschrittes Prüfen wird der Zustand der Komponente festgestellt und in die Kategorien Wiederverwendung oder Recycling einsortiert, was eine Schlüsselstelle des Aufbereitungsprozesses darstellt. Für eine mögliche Wiederverwendung müssen daher alle Komponenten vor der erneuten Montage geprüft werden. Ziel des Prozessschrittes ist es, die gesamte Funktionsfähigkeit sicherzustellen, sowie den Zustand der Komponente bestmöglich zu bestimmen. Innerhalb dieses Prozessschrittes findet die größtmögliche Wertschöpfung des Refabrikationsprozesses statt, da alle Komponenten bis zu diesem Schritt ihren eigenen Schrottwert besitzen und bei positiver Bewertung einen geminderten Neuteilwert zugeschrieben bekommen. Für die Bewertung und Zustandsbestimmung jeder einzelnen Komponente ist es notwendig, geeignete Prüfverfahren sowie eigene Prüfumfänge mit den jeweiligen Grenzen zu entwickeln. Hierfür müssen die Ausfallursachen und mögliche Fehlfunktionen definiert und diese systematisch analysiert werden. Die Entwicklung geeigneter Prüfumfänge und Anlagen steht jedoch im wirtschaftlichen Zielkonflikt zwischen größtmöglicher Wiederverwendungsquote der Komponente und möglichst geringem Prüfaufwand, der nur einen Teilbetrag des Neuteilpreises der Komponente betragen darf. Eine Steigerung der Wiederverwendungsquote ist in der Regel durch aufwändigere Prüfmethode und einer damit verbundenen genauen Zustandsbestimmung der Komponente, die es erlaubt die Komponente in einen zuvor definierten Zustandsbereich einzusortieren, möglich. Ist eine klare Einsortierung in den definierten Zustandsbereich nicht möglich, muss die Komponente aus Qualitätssicht dem Recycling-Prozess zugeführt werden. Eine Entwicklung geeigneter Prüfumgebungen, im Rahmen

des genannten Zielkonfliktes, ist in den meisten Fällen nur durch eine iterative Erweiterung der Prüfumfänge und eine Anpassung der Grenzwerte mit alterndem Fahrzeugfeld und Zugewinn der Erkenntnisse der Bauteilalterung unter realen Bedingungen möglich. Ziel ist es daher, systematisch geeignete Prüfumgebungen zu entwickeln, die bedarfsgerecht bei wirtschaftlicher Relevanz erweitert werden können, und dynamisch mit steigendem Wissen über das Ausfallverhalten der Produkte die verwendeten Grenzwerte innerhalb des Refabrikationsprozesses anzupassen.

### **Methodisches Vorgehen**

Um das Ziel einer wirtschaftlichen Prüfumgebungsentwicklung zu ermöglichen, werden gängige Methoden der Zuverlässigkeitstechnik systematisch angewendet. Hierfür wird in einem ersten Schritt die zu betrachtende Komponente oder eine gesamte Baugruppe, falls diese nicht weiter demontiert werden kann, anhand von Kriterien, wie der Verfügbarkeit bzw. dem Einkaufspreis der Komponente, der Prüfbarkeit und dem Ermüdungsverhalten/Schadensmechanismen, bewertet und ausgewählt. Um den Bauteilzustand (engl. State-of-Health) später prognostizieren zu können, müssen Alterungsmechanismen bauteilspezifisch betrachtet und diese in der späteren Prüfung berücksichtigt werden. Nach der Festlegung der Komponente und Bestimmung der wesentlichen Alterungsmechanismen werden in einem darauffolgenden Schritt Systemanforderungen definiert. Dies beinhaltet funktionelle sowie technische Anforderungen, bspw. die Hauptfunktionen sowie zulässige Temperaturbereiche und mechanische Belastungen.

Basierend auf den Systemanforderungen kann eine Systemanalyse durchgeführt werden. Dabei wird eine Systemgrenze um die betrachtete Komponente gelegt und Energie-, Material- und Informationsströme betrachtet. Ziel ist es, jede Interaktion der betrachteten Komponente in diese drei Hauptgruppen einzugliedern und relevante Einflussgrößen, die sich auf das Alterungsverhalten auswirken, wie Temperaturströme und auftretende Kräfte, zu berücksichtigen. Dieses Vorgehen wird anschließend im Falle einer betrachteten Baugruppe für jede Einzelkomponente wiederholt. Die gesuchten Prüfumfänge werden auf Basis einer Zuverlässigkeitsanalyse auf Funktionsstruktur mithilfe einer Fehlerbaum Analyse (engl. FTA) durchgeführt. Ziel ist es, Fehlfunktionen und Fehlerursachen systematisch aufzuzeigen und geeignete Prüfschritte zu definieren und messbare Größen bzw. Eigenschaften abzuleiten.

Auf Basis der abgeleiteten Prüfumfänge kann eine geeignete Prüfumgebung entwickelt werden. Die für die Prüfung benötigten Grenzwerte werden zu Beginn aus Messreihen von Neuteilen und Lastenheftanforderungen der ausgewählten Komponente bzw. Baugruppe abgelei-

tet. Auf dem zu diesem Zeitpunkt hergestellten Startsetup (Prüfumfang und Grenzwerte) können ausgefallene Komponenten geprüft und Prüfergebnisse gesammelt werden. In definierten Intervallen werden diese analysiert, um sukzessive die Prüfumgebung und die benötigten Grenzwerte anzupassen, mit dem Ziel den Refabrikationsprozess wirtschaftlicher zu gestalten. Bild 2 zeigt den beschriebenen Prozess in Form eines Ablaufdiagramms.

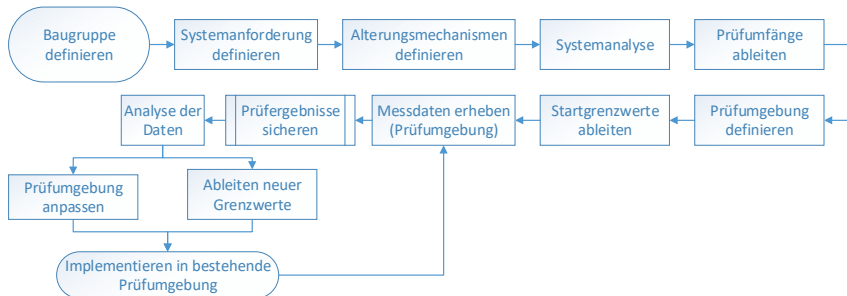


Bild 2 zeigt das systematische Vorgehen als Flussdiagramm zur Grenzwertfindung und -Optimierung der verwendeten Prüfumgebung.

Das beschriebene Vorgehen soll an einem Elektroniksatz eines Automatikgetriebes angewendet werden. Auf Basis dieser Erkenntnisse sollen die bestehenden Prüfkriterien angepasst bzw. erweitert werden und die zu Beginn konservativ gewählten Grenzwerte durch neue systematisch abgeleitete Grenzwerte, die speziell in der Tauschaufbereitung Anwendung finden, ersetzt werden. Dies ist notwendig, um das volle Potential der Tauschaufbereitung, die ein zweites Produktleben als Ziel hat, auszuschöpfen. Ziel ist es dabei, systematisch die Wiederverwendungsquote der Vollintegrierten Getriebesteuerung ohne Qualitätsverluste zu erhöhen sowie die Prüfumgebung unter wirtschaftlichen Aspekten bedarfsgerecht anzupassen bzw. zu erweitern. Für das beschriebene Vorgehen werden Rückläufer mit hohen Ausfallzeiten benötigt, die zu Beginn noch nicht zur Verfügung stehen. Diesem Umstand zufolge sollen die Grenzen iterativ erweitert werden.

### Anwendungsbeispiel Vollintegrierte Getriebesteuerung (VGS)

Bei der Einführung von neuen Produkten in das Aufbereitungsportfolio, wie der aktuellen Getriebegeneration 9G-TRONIC (siehe Bild 3), werden zu Beginn kostenintensive Baugruppen

wie die elektrohydraulische Steuerung (EHS) (Bild 4) als eigenes Produkt angeboten und aufbereitet. Diese befindet sich über der Ölwanne des Getriebes und übernimmt die gesamten Regel- und Steueraufgaben des Getriebes.

Die EHS beinhaltet die gesamte hydraulische Steuerung inklusive der elektrischen Zusatzölpumpe, der Magnetventile und die Vollintegrierte Getriebesteuerung (VGS), welche über den Fahrzeug-CAN mit den restlichen Steuergeräten des Fahrzeuges kommuniziert.




Bild 3: Schnittdarstellung des 9G-Tronic mit der verbauten elektrohydraulischen Steuereinheit zwischen den Planetensätzen und der Ölwanne (Quelle: Daimler AG)




Bild 4: Elektrohydraulische Steuereinheit (EHS) des Getriebes als Baugruppe mit der vollintegrierten Getriebesteuerung (VGS) (Quelle: Daimler AG)

### Baugruppe und Systemanforderungen definieren

Innerhalb des Getriebes stellt die VGS eine der kostenintensivsten Einzel-Baugruppen des Getriebes dar und soll daher auf eine mögliche Wiederverwendung hin untersucht werden. Die betrachtete VGS beinhaltet die gesamte Sensorik, sowie Leistungstreiber und das Getriebe-steuergerät (ECU) des Getriebes. Die VGS wird in die nachfolgenden Hauptkomponenten gegliedert, welche alle für die Entwicklung einer Prüfumgebung und für die spätere Überprüfung relevant sind:

- Steuergerät (engl. ECU)
  - Mikrocontroller
  - CAN-Controller
  - AD- und DA-Wandler
- Drehzahlsensoren (Aktiv- und Passiv- Differenz-Hall-Sensoren)
- Drucksensor (Basierend auf einem DMS-Messbrückenmembran)
- Temperatursensor
- Leistungstreiber für die elektronische Zusatzölpumpe
- Entstör Einheit
- Positionssensor der Parksperre

Für eine mögliche Wiederverwendung müssen alle Komponenten auf ihre Ausfallmechanismen geprüft und ihre Funktionsfähigkeit sichergestellt sein sowie der Zustand der VGS bestmöglich bestimmt werden. Hierfür müssen die Ausfallursachen bekannt, mögliche Fehlfunktionen definiert und diese systematisch analysiert werden.

Die gesammelten Prüfstandsdaten der späteren Prüfung innerhalb des Refabrikationsprozesses werden in regelmäßigen Abständen analysiert. Dabei ist das Ziel der Datenanalyse, die Belastungen und Ausfallursachen der untersuchten VGS besser zu verstehen. Da die geprüften Komponenten aus dem Feldeinsatz stammen, besitzen sie keine Einflüsse, die durch raufende Versuche hervorgerufen werden. Allerdings kann auf das Belastungsprofil nur durch die folgenden gewonnenen Steuergeräte-Daten geschlossen werden:

- Betriebszeit der ECU
- Fehlerspeichereinträge
- Temperaturhistorie
- Gangspezifische Schadenszahlen

### **Alterungsmechanismen**

Im Falle der in dieser Arbeit thematisierten VGS handelt es sich um ein mechatronisches Verbundmodul. Mechatronische Systeme unterliegen während ihrer Nutzung unterschiedlichen Alterungs- und Verschleißmechanismen. Diese Alterung führt nicht zwangsweise zu einem Totalausfall der Komponente, sondern kann zu abweichenden Eigenschaften und Verhalten der Komponente führen. Dies können geänderte Stromkennlinien bzw. abgeschwächte Magnetfelder sein, die zu Fehlfunktionen der VGS führen und müssen bei der späteren Prüfung beachtet werden.

Bauteile ermüden aufgrund von Verschleißprozessen durch Belastungen. Dabei wird zwischen den Belastungen unterschieden, die unter Betriebsbedingungen oder aufgrund Belastungen außerhalb ihrer Spezifikation verursacht wurden. Diese führen zu einer beschleunigten Alterung und erhöhen das Ausfallrisiko signifikant. Hierunter fallen unter anderem bestimmte Temperaturbereiche, welche für die VGS nur kurzzeitig zugelassen sind und innerhalb des Normalbetrieb nicht erreicht werden. Relevant für die Aufbereitung sind beide Kriterien, jedoch führt ein Betrieb außerhalb der Spezifikation oder in definierten Grenzbereichen zum direkten Ausschluss für eine mögliche Wiederverwendung. Somit muss eine Überschreitung der Spezifikationsgrenzen erfasst und ausgewertet werden. Im Fall der VGS werden Übertemperaturen gesondert bewertet.

Alterungsmechanismen bzw. sogenannte Stressfaktoren bei elektrischen Komponenten beziehen sich nicht nur auf die Temperatureinflüsse, sondern können in innere und äußere Faktoren gegliedert werden und sind nachfolgend aufgeführt.

**Äußere Einflüsse:**

- Temperatur
- Schock, Vibration
- Feuchtigkeit
- Partikel und Staub

**Interne Stressfaktoren:**

- Verlustwärme
- Eigenspannungen
- Strom, Strom-/Leistungsdichte
- Spannung, Feldstärke

Diese können mit ihrem Wertebereich alle innerhalb der definierten Spezifikation liegen und führen im Laufe der Zeit zu einer Alterung und dadurch zu einer erhöhten Ausfallwahrscheinlichkeit der Komponente [6]. Untersuchungen eines exemplarischen Systems haben gezeigt, dass Temperatureinflüsse (Temperaturen innerhalb und außerhalb der Spezifikation sowie Temperaturwechsel) mit ca. 50 % den größten Einfluss auf das Alterungsverhalten von elektronischen Bauteilen haben [7]. Vibrationen und Schockbelastungen verursachen hingegen ca. 20 % der Ausfälle. Auf Feuchtigkeit können knapp 20% zurückgeführt werden. Der Einfluss von Staub hingegen macht in dieser Studie unter 10% aus. Die beiden zuletzt genannten Belastungsarten spielen bei der betrachteten Komponente eine untergeordnete Rolle, da alle Komponenten, außer Kontaktstellen, durch ein Spitzgussverfahren gekapselt werden. Jedoch können Verunreinigungen durch die Zirkulation des Getriebeöls an Kontakte und Schnittstellen gelangen und sich dort anlagern. Folgeerscheinung sind Kurzschlüsse oder Widerstandserhöhungen, die die Funktionsfähigkeit der VGS und damit des Getriebes einschränken.

**Systemanalyse und ableiten der Prüfumfänge**

Auf Basis der Alterungsmechanismen und der Systemanforderung der VGS wird eine Systemanalyse durchgeführt. Hierbei werden in einem ersten Schritt die Wechselwirkungen auf die Systemgrenze der VGS näher betrachtet, die wiederum Einfluss auf die Alterung der Komponenten haben. In diesem Schritt werden alle Interaktionen den drei Hauptgruppen: Energie, Materialtransport und Informationsaustausch (Informationsströme) zugeordnet und betrachtet. Daraus ergeben sich die Hauptfunktionen der VGS, welche bei einer Prüfung berücksichtigt und abgedeckt werden müssen. Das beschriebene Vorgehen wird ebenfalls im Falle der Baugruppe VGS auf Bauteileben durchgeführt, um Einflussgrößen, die die Alterung der betrachteten Komponente beeinflussen, zu berücksichtigen. In einem weiteren Schritt werden die zuvor definierten Funktionen der VGS mithilfe der Fehlerbaumanalyse (FTA) untersucht und mögliche Fehlfunktionen und deren Ursachen abgeleitet. Hieraus ergeben sich geeignete Prüfmöglichkeiten und Prüfgrößen, die in der späteren Bauteilprüfung verwendet werden.

Black-Box-Tests ermöglichen eine wirtschaftliche Überprüfung einzelner Funktionen der VGS und finden in einem frühen Stadium des Produktlebenszyklus innerhalb des Refabrikationsprozesses häufig Anwendung. Hierbei werden beispielhaft Sensoren stimuliert und das Ergebnis über die Fahrzeug-CAN Schnittstelle der VGS ausgelesen. Dies ermöglicht eine hohe Prüfabdeckung gesamter Funktionsstrukturen. Alternativ werden Prüfumfänge erweitert und Messgrößen an geeigneten Kontaktpunkten innerhalb der Funktionsstruktur ausgelesen, um einen höheren Informationsgrad zu erhalten und so auf den Zustand der Komponente schließen zu können.

### Prüfumgebung

Zur Überprüfung der VGS wird ein Hardware-in-the-Loop Prüfstand der Firma Hoerbiger verwendet mit einem speziell aufgebauten und eingesetzten Prüfadapter, siehe Bild 5. Das Prüfsystem verfügt über eigene Stromquellen und Frequenzgeneratoren sowie Messsysteme zur Erfassung von Strömen, Spannungen und Frequenzen. Das Prüf- und Messsystem ist über eine Schnittstelle mit dem „Prüfadapter“ (Bild 6 & Bild 7) verbunden. Hierdurch kann das Grundsystem „Prüfstand“ für unterschiedliche Getriebeelektroniksätze verwendet werden und senkt die Prüfkosten des einzelnen Produkts.




Bild 5: Universalprüfgerät mit eingesetztem Prüfadapter für das Produkt NAG3 VGS

Die Prüfadapter werden individuell für die jeweilige Getriebevariante und ihre Steuerung aufgebaut. Bei der Produkteinführung in das Refabrikationsportfolio liegt der Fokus auf einer

Prüfstrategie, die den gesamten Funktionsumfang abdeckt. Dabei sollen Funktionen so einfach wie möglich geprüft werden. Hierbei kann von einer agilen Prüfentwicklung gesprochen werden, da in der späteren Datenanalyse gezielt das mögliche Verbesserungspotenzial aufgezeigt werden kann und kostenoptimiert Funktionen hinzugefügt werden. Dieses Vorgehen ermöglicht es, auch bei geringen Stückzahlen wirtschaftlich Komponenten zu überprüfen und führt zu einer Kostenoptimierung der Prüfumgebung. Im Falle der hier beschriebenen VGS besteht der Prüfadapter u.a. aus den im Getriebe verbauten Komponenten, die direkt mit der VGS interagieren (Bild 5):

- Magnete der Magnetregelventile
- Elektrische Zusatzölpumpe
- Parksperrenmagnet
- Angetriebene Polräder zur Anregung der Drehzahlsensoren
- Leistungswiderstände




Bild 6: Geöffneter Prüfadapter ohne VGS und Prüfsystem. Die VGS wird mithilfe von zwei Steckern und Federkontakten kontaktiert.




Bild 7: Wartungsklappe des NAG3 Prüfadapters geöffnet. Zeigt die intern verbauten Prüflasten in Form von elektrischen Widerständen und Stimulatoren wie den angetriebenen Polrädern.

Die speziell aufgebauten Prüfadapter ermöglichen es, alle Funktionen der VGS getriebenah zu überprüfen. Dabei durchläuft das Prüfprogramm über 250 Mess- und Prüfschritte in denen Aktoren angesteuert, Sensoren angeregt und Fehlerspeicher ausgelesen werden. Innerhalb jedes Prüfschrittes werden die ausgegebenen Signale bzw. bereitgestellten Energieströme in Form von Frequenzen, Strömen oder Spannungen erfasst. Die hierdurch erzeugten Mess-



bzw. Prüfergebnisse werden mit hinterlegten Daten verglichen und führen zu einer Bewertung der Komponente. Alle generierten und ausgelesenen Daten werden abgelegt und stehen für eine spätere Analyse zur Verfügung.

### **Ableiten der Startgrenzwerte bei der Einführung neuer Produkte in das Aufbereitungsportfolio**

Die zu Beginn benötigten Grenzwerte basieren auf den Neuteilanforderungen und werden bewusst konservativ gewählt. Ziel ist es, mit diesen Startwerten mögliche Frühausfälle gezielt über den Refabrikationsprozess wirtschaftlich aufzubereiten, da diese Aggregate nur geringe Belastungen und Betriebszeiten erfahren haben. Um jedoch das gesamte Potenzial in der Refabrikation nutzen zu können, müssen gezielt Feldausfälle untersucht werden, um so sukzessive die Grenzen an ein Optimum von Qualität und Wirtschaftlichkeit anzunähern. Dies gelingt durch die bereits angesprochene Ausnutzung der Überdimensionierung, die aufgrund der kurzen Entwicklungszyklen und damit verbundenen kurzen Versuchszeiträume zur Absicherung der geforderten Lebensdauer der entwickelten Komponenten einhergeht. Hierfür ist eine Analyse der betrachteten Komponente mit Laufleistungen oder Einsatzzeiten, die nahe am Auslegungspunkt liegen oder diesen bereits überschritten haben, zielführend. Eine Untersuchung solcher Komponenten ist in der Regel in ausreichender Stückzahl nur mit einem alternenden Fahrzeugfeld möglich.

### **Datenanalyse der gewonnenen Prüfstandsdaten und Diskussion der Ergebnisse**

Für die Analyse stehen 252 Messungen aus einem Aufbereitungsstandort zur Verfügung, die mit dem oben beschriebenen Messaufbau durchgeführt wurden. Aus diesem Datensatz konnten 218 eindeutige Datensätze extrahiert werden. Eine eindeutige Zuordnung der Datensätze ist über eine hinterlegte Fortschrittszahl der Komponente möglich. Bei den restlichen 34 Datensätzen handelt es sich um Wiederholprüfungen einzelner fehlerhafter Steuereinheiten, welche einer Zweit- bzw. Dritt-Prüfung unterzogen wurden. Diese führten jedoch zu keinem anderen Prüfergebnis.

Bei der Analyse der Daten liegt der Schwerpunkt zu diesem Zeitpunkt des Produktlebenszyklus auf den Prüfschritten, die zu einem negativen Prüfergebnis und somit zum Recyceln der VGS führen. Die Wiederholprüfungen werden genutzt, um die Prozessfähigkeit des Systems zu überwachen und bestätigen die Messfähigkeit des Systems. Die Wiederholprüfungen werden in der nachstehenden Betrachtung nicht weiter thematisiert und die Datenmenge für die Analyse wird entsprechend auf 218 Datensätze reduziert. Eine Analyse der 218 Getriebesteuerungen zeigt, dass insgesamt 39 % VGS die Prüfung nicht bestanden haben. Auffällig zeigt

sich dabei die Überprüfung des internen Drucksensors, welche überdurchschnittlich oft nicht bestanden wurde. Hierbei handelt es sich um einen Black-Box-Test in Form eines Funktions-tests. Diese Prüfung macht über 48 % der Beanstandungen des Prüfsystems aus. Die zweithäufigste Beanstandung durch das Prüfsystems, in Höhe von 43 %, erfolgte durch einen der drei verbauten Drehzahlsensoren. Die restlichen fehlerhaften Überprüfungen verteilen sich mit 9 % auf die anderen Prüfschritte des Steuergerätes.

Eine Analyse der fehlerhaften Steuereinheiten zeigt keine Abhängigkeit zwischen den Produktionszeiträumen der Steuergeräte. Die Fehler streuen über den gesamten Produktionszeitraum, den die Stichprobe abdeckt, dies zeigen die Ergebnisse des Drucksensors beispielhaft in Bild 8. Die betrachtete Stichprobe beinhaltet dabei Produktionszeiträume der Komponenten aus den Jahren 2014 bis 2019. Somit können die vom Prüfsystem beanstandeten Steuereinheiten nicht auf einzelne Produktionschargen zurückgeführt werden. Im Verhältnis der hohen produzierten Stückzahl des Getriebes sind hier keine Auffälligkeiten erkennbar.




Bild 8: Ermittelter Druck jeder Prüfung aufgetragen über das Herstellungsdatum der VGS. Eine auffällige Produktionscharge kann nicht festgestellt werden.

## Drucksensor

Die Messergebnisse des Drucksensors zeigen eine Streuung der Messwerte weitestgehend innerhalb der Lastenheftvorgabe. Es ist ein Trend über den zeitlichen Verlauf der durchgeführten Prüfungen zu erkennen, welcher in Bild 9 dargestellt ist. Aufgrund der systematischen Abweichung der einzelnen Prüfgruppen, die jeweils innerhalb eines Produktionstages geprüft wurden, und der geringen Überschreitung der hinterlegten Grenzwerte wird nicht von einer Bauteilalterung ausgegangen. Bei der Überprüfung der Funktion des Drucksensors werden festhinterlegte Grenzwerte zur Bewertung der Funktionsfähigkeit verwendet. Hierbei werden aktuell noch keine Umwelteinflüsse und die dadurch ändernden Umgebungsdrücke berücksichtigt. Um die mögliche Steigerung der Wiederverwendungsquote zu bestimmen, werden Wetterdaten aus einer naheliegenden Wetterstation genutzt, um eine rechnerische Kompensation der Umwelteinflüsse zu ermöglichen. Die Auswertung der Daten mit den dynamischen Grenzwerten ist in Bild 9 zu sehen und ermöglicht eine wirtschaftliche Bewertung der Prüfumgebung und führt dadurch zu einer zielgerichteten iterativen Weiterentwicklung der Prüfspezifikation im Rahmen der Tauschaufbereitung. Durch die beschriebene Maßnahme kann die Fehlerquote dieser Prüfung rechnerisch um ca. 80 % Prozent gesenkt werden.




Bild 9: Zeitlicher Verlauf der durchgeführten Prüfungen. Angepasste Grenzwerte auf Basis von Wetterdaten zur Kompensation des Einflusses durch Luftdruckänderungen.

## Analyse Drehzahlsensor

Bei der zweithäufigsten Beanstandung des Prüfsystems handelt es sich um die Überprüfung eines der verbauten Drehzahlsensoren. Eine direkte Auffälligkeit analog des Verhaltens des Drucksensors konnte bei der Überprüfung des Drehzahlsensors nicht festgestellt werden. Von einem korrekten Antrieb des Polrades wird ausgegangen, da sich alle drei Polräder auf der identischen angetriebenen Welle befinden (siehe Bild 7) und nur ein Sensor das Fehlerbild zeigt. Im weiteren Vorgehen wird das Ausfallverhalten mithilfe des Wahrscheinlichkeitsnetzes betrachtet, welches in Bild 10 für den betrachteten Sensor dargestellt ist. Das Wahrscheinlichkeitsnetz in Bild 10 zeigt einen S-förmigen Verlauf, weshalb von unterschiedlichen Ausfallmechanismen ausgegangen wird. Daher werden die Daten anhand ihrer Ausfallzeiten in drei Gruppen geclustert und jeweils eine separate Weibullanalyse durchgeführt, siehe Bild 11. Zum aktuellen Zeitpunkt wird vermutet, dass drei unterschiedliche Fehlermechanismen zu den Beanstandungen durch das Prüfsystem geführt haben. Hierbei kann jedoch noch keine Aussage getroffen werden ob die Prüfung selbst verbessert werden muss oder die Komponente bzw. eine Teilkomponente innerhalb der Funktionsstruktur ausgefallen ist, da es sich hierbei ebenfalls im aktuellen Stadium um einen Black-Box-Test der Funktion „Drehzahlerfassen“ handelt. In einem nachgelagerten Schritt ist eine genauere Analyse der Wirkkette durchzuführen, um mögliche Fehlerquellen wie beispielhaft einen Leiterbruch ausschließen oder bestätigen zu können.




Bild 10: Wahrscheinlichkeitsnetz aller 33 Fehler des Drehzahlsensors der untersuchten Stichprobe. (Abbildungen erstellt mithilfe des predictr [8])




Bild 11: Wahrscheinlichkeitsnetz der gruppierten Fehler mit einem 90 % Vertrauensbereich. (Abbildungen erstellt mithilfe des predictr [8])

#### 4. Fazit und Ausblick

Die vorgestellte Herangehensweise eignet sich, um Prüfumfänge für Refabrikationsprozesse abzuleiten und bestehende Prüfsysteme systematisch zu optimieren. Im Fokus liegt hierbei das wirtschaftliche Optimum zwischen Wiederverwendungsquote und Prüfkosteneinsatz innerhalb der Tauschaufbereitung. So konnte durch die systematische Analyse des Drucksensors die Fehlerquote innerhalb des Datensatzes von 39 % auf 24 % gesenkt werden. Zudem konnte gezeigt werden, dass eine möglichst frühe Umsetzung der Tauschaufbereitung von hochpreisigen Komponenten mit konservativen Grenzen einen direkten wirtschaftlichen Vorteil bietet.

Das alternde Fahrzeugfeld ermöglicht es, durch die Analyse der gewonnenen Daten und dem dadurch steigenden Wissen über das Ausfallverhalten einzelner Komponenten, die benötigten Grenzwerte anzupassen und so die Wiederverwendungsquote zu erhöhen.

Im weiteren Verlauf sollen die gesammelten Ausfalldaten mit den ausgelesenen Temperaturkollektiven und Betriebszeiten verknüpft werden, um so den Bauteilzustand (State-of-Health)

besser zu bestimmen und die festgestellten Fehlfunktionen zu analysieren. Des Weiteren sollen die Leistungstreiber der Getriebesteuerung, welche die Ströme für die Ansteuerung der Regelmagnete und der elektrischen Zusatzölpumpe bereitstellen, über das beschriebene Vorgehen analysiert werden und so neue Grenzwerte für weitere Prüfungen abgeleitet werden. Eine genauere Bestimmung der Zustandsbewertung nimmt mit alterndem Fahrzeugfeld an Bedeutung zu, da kundenspezifische Belastungskollektive besser erkannt und im Refabrikationsprozess berücksichtigt werden können.

### Literaturquellen

- [1] Steinhilper, Rolf: Remanufacturing - The ultimate form of recycling, Stuttgart 1998.
- [2] Bertsche B. Reliability in Automotive and Mechanical Engineering – Determination of Component and System Reliability. Springer-Verlag Berlin Heidelberg, 2008.
- [3] DIN EN 13306: 2019-02, Maintenance terminology
- [4] Dr.-Ing. Ulrike Lange: Kurzanalyse Nr. 18: Ressourceneffizienz durch Remanufacturing - Industrielle Aufarbeitung von Altteilen, Berlin 2017
- [5] Andreas, Kroner: Prediction of the remaining useful life of transmission components within a remanufacturing process to ensure the second product life. pp.825-832.  
[https://paginas.fe.up.pt/~irf/Proceedings\\_IRF2020/](https://paginas.fe.up.pt/~irf/Proceedings_IRF2020/)
- [6] Tränkler, H.-R. u. Reindl, L.: Sensortechnik. Berlin, Heidelberg: Springer Berlin Heidelberg 2014
- [7] ZVEI - Zentralverband Elektrotechnik- und Elektronikindustrie e. V.: Handbook for Robustness Validation of Automotive Electrical / Electronic Modules (2013)
- [8] Tevetoglu, Tamer: (2021, January 22). tvtoglu/predictr: V0.1.13 (Version V0.1.13). Zenodo. <http://doi.org/10.5281/zenodo.4456183>

# Verfahren zur Prognose von Garantiekosten und Instandhaltungsaufwand

## Method for forecasting warranty costs and maintenance effort

**Torsten Renz, Dr.-Ing. Harald Jung,**  
IZP Dresden mbH, Dresden

### Kurzfassung

Die Prognose von Ausfallhäufigkeiten ist ein wesentlicher Aspekt bei der Abschätzung von Garantie- und Kulanzkosten. Schwierigkeiten entstehen dabei durch den hohen Zensierungsanteil und die unterschiedliche Qualität zwischen Ausfall- und Gutläuferdaten, sowie die Verwendung verschiedener Lebensdauermerkmale. Es wird ein Verfahren vorgestellt, welches über eine empirische Schätzung die Ausfallanzahlen für den anfänglichen Einsatzzeitraum berechnet und für den zukünftigen Einsatzzeitraum eine Prognose einschließlich Vertrauensbereich erstellt. Die Methodik kann sowohl für die Bildung von Risikorücklagen für Ausfallfolgekosten als auch für die Planung von Instandhaltungskapazitäten und Ersatzteilen und damit für die Optimierung der Lagerhaltung genutzt werden.

### Abstract

Forecasting of failure frequencies is an essential aspect of estimating the guarantee and goodwill costs. A high censoring part, heterogeneous quality of failure and censored data and the use of different lifetime scales due to a complex analytical problem. This paper shows a method, how an empirical estimation of failure numbers can be done in such a situation. The forecast will be realized with indication of a confidence area. The method can be used for formation of savings for failure impacts as well as prediction of spare part demands and the improvement of stock holding.

### 1. Rahmensituation und Ziel

Stellen Sie sich vor, Sie sind als Technikbetreiber verantwortlich für die Instandhaltung in einem Maschinenpark bzw. einer Fahrzeugflotte oder Sie sind als Hersteller mit der Abwicklung der After Sales Geschäfte betraut. Sie wissen, dass es in der zu betreuenden Technik

Ausfälle geben wird und müssen dafür Sorge tragen, dass durch geeignete Maßnahmen (Instandhaltung, Produktoptimierung, Ersatzteilversorgung) die erforderliche Verfügbarkeit gewährleistet werden kann, ohne dass es zu einem unerwarteten Kostenanstieg kommt. Zu den Eignungsmerkmalen der IH zählen die Bereitstellung ausreichender IH-Kapazitäten in Form von Werkstätten und qualifiziertem Personal und die Bereithaltung der benötigten Ersatzteile. Natürlich ist auch die Einschätzung der resultierenden Kosten für die IH von Interesse. Eine effiziente Planung der IH wird ihnen nur dann gelingen, wenn Sie abschätzen können, welche Instandhaltungstätigkeiten und Arbeitsumfänge auf Basis des Zuverlässigkeitsverhaltens der Technik zu erwarten sind. Eine wesentliche Planungsgrundlage dafür ist eine belastbare Abschätzung/ Prognose der Ausfallanzahlen. Genau darum soll es im vorliegenden Beitrag gehen. Von besonderer Bedeutung sind im Rahmen der Instandhaltung die kleinsten austauschbaren Einheiten. Wenn nachfolgend von Ausfallanzahlen die Rede ist, bezieht sich das stets auf eine bestimmte kleinste tauschbare Einheit als Betrachtungsobjekt der Instandhaltungsplanung.

## 2. Eingangsinformationen

Die zu betrachtenden Komponenten sind bereits eine gewisse Zeit (Vorlaufzeit) im gleichen Umfeld in Betrieb, wie es auch weiterhin vorgesehen ist. Nicht ausgefallene Komponenten sind als Gutläufer zu betrachten, die ihre Lebensdauer im weiteren Betrieb fortsetzen. Sämtliche Ausfälle in der Vorlaufzeit wurden registriert. Die betroffenen Komponenten wurden durch später produzierte Komponenten ersetzt. In Bild 1 ist dargestellt, was aus der Vorlaufzeit zahlenmäßig erfasst wurde.

Sämtliche Daten ordnen sich in ein Zeitraster ein. Im Beispiel handelt es sich um ein Jahresraster; es könnten aber auch Quartale, Monate, ... sein. Die vertikale Ausdehnung im Diagramm zeigt den zeitlichen Produktionsfortschritt und die horizontale Richtung die Betriebsdauer der Komponenten. Pro Jahr (also pro Rasterelement) sind die Produktionszahlen bekannt. Die Inbetriebnahme erfolgt gleichmäßig verteilt innerhalb des Jahres. Eine genauere Datenermittlung erfolgt nur dann, wenn eine Komponente ausfällt (im Bild durch ein Kreuz dargestellt). In diesem Fall wird die Lebensdauer in Zeiteinheiten genau bestimmt. Außerdem wird die Lebensdauer in einer zweiten Einheit angegeben. Es handelt sich um eine Einheit, die die tatsächliche Belastung charakterisieren möge. Das könnte beispielsweise die Laufstrecke oder eine Anzahl von Betätigungen, Umdrehungen usw. sein. Die Informationen zu den Gutläufern – das sind die Komponenten, die bis zum Beobachtungsende nicht ausfallen – sind wesentlich gröber. Es ist das Produktionsjahr und das Beobachtungsende be-



kennt, woraus sich eine zeitskalierte rechtzensierte Lebensdauerabschätzung grob ableiten lässt.




Bild 1: Aus der Vorlaufzeit bekannte Daten

### 3. Vorausliegende Produktionsmengen und Analyseziel

Mit den vorliegenden Daten ist es möglich, die Fehleranzahlen für die Vergangenheit zu bestimmen. Pro Zeitscheibe im Zeitraster (Spalten in Bild 1) müssen lediglich die Ausfälle zusammengezählt werden. Ziel ist es nun, entsprechende Anzahlen für den vorausliegenden Betrieb zu prognostizieren. Kandidaten für Ausfälle in der Zukunft sind die Gutläufer (zur Gegenwart noch nicht ausgefallene Komponenten) und die in der Zukunft liegenden Inbetriebnahmen. Letztgenannte werden auch in Form von Produktionsmengen pro Zeitscheibe im Zeitraster angegeben. Das Schema aus Bild 1 erweitert sich um Spalten und Zeilen, die dem Prognosezeitraum zuzuordnen sind (Bild 2).




Bild 2: Vollständige Beschreibung des Analyseproblems

In Bild 2 ist das Ziel der Analyse zu erkennen: Es ist die prognostische Fortführung der Ausfallanzahlen über die Gegenwart hinaus. Dafür ist eine Gesetzmäßigkeit, nach der die zukünftigen Ausfälle eintreten, zu erkennen und der Schluss auf die Fehleranzahlen zu finden.

#### 4. Herausforderungen bei der Prognose der Ausfallanzahlen

Es gibt nicht nur ein Problem, sondern gleich mehrere.

- (1) Die im Prognosezeitraum liegenden Ausfälle sind unbekannt und zufällig. Mit Mitteln der Wahrscheinlichkeitsrechnung, Simulation und Statistik kann nur etwas über ihre wahrscheinliche Position gesagt werden.
- (2) Das Gleiche gilt für die Ausfallzahlen in den einzelnen Jahren im Prognosezeitraum. Mit Methoden der Statistik können Konfidenzbereiche und Kenngrößenschätzungen vorgenommen werden.
- (3) Die Lebensdauerdaten aus der Vergangenheit weisen einen sehr hohen Anteil an Rechtszensierungen auf. Eine klassische Verteilungsschätzung ist nicht möglich. Die Statistik stellt aber auch für die beschriebene Situation eine Methode bereit.
- (4) Für die Realisierung der Prognose benötigt man unter Umständen die Kenntnis des Ausfallverhaltens in einem Bereich, der über den Anpassungsbereich hinausgeht. Mit Hilfe einer parametrischen Anpassung wird eine derartige Extrapolation möglich. Diese sollte aber durch Erfahrungen gestützt sein!
- (5) Die Lebensdauerdaten unterliegen unterschiedlichen Skalierungen. Während die vollständigen Daten (Beobachtung eines Ausfalls) sowohl eine Information zur absolvierten Zeit als auch zur zurückgelegten Laufstrecke enthalten, gibt es für die Gutläu-

fer nur eine grobe Information zur absolvierten Zeit. Dieser Informationsmangel wird durch die Annahme einer Laufleistungsverteilung ausgeglichen (Laufleistung gemessen etwa in „km pro Jahr“) .

## 5. Schätzung der Ausfallanzahlen

Die Ausfallanzahlen der Vergangenheit können leicht aus den Beobachtungen bestimmt werden. Dazu müssen lediglich alle Ausfallzeitpunkte in die passenden Intervalle eines Zeitrasters eingeordnet werden (siehe Bild 3).




Bild 3: Registrierung der beobachteten Ausfälle

Die folgenden Schritte dienen der Schätzung der Ausfallanzahlen in der Zukunft.

1. Schritt: Schätzung der Lebensdauerverteilung bezüglich dem Lebensdauermerkmal Laufstrecke (km) aus den bisherigen Beobachtungen
2. Schritt: Simulation des Ausfallzeitpunktes für alle Gutläufer, die zum Beobachtungsende vorliegen
3. Schritt: Simulation des Ausfallzeitpunktes für alle Betrachtungseinheiten, die in der Zukunft in Betrieb genommen werden
4. Schritt: Einordnung der Ausfallzeitpunkte in ein Zeitraster
5. Schritt: Vielmalige Wiederholung der Schritte 2 – 4, anschließende statistische Auswertung der Anzahlen pro Zeitintervall

### Schritt 1

Ziel ist es, die Lebensdauerverteilung bezüglich des Lebensdauermerkmals Laufstrecke zu schätzen. Da die Laufstrecke im vorliegenden Fall als die belastungsrelevante Größe ange-

sehen wird, ist es ratsam die zufällige Lebensdauer in der Einheit einer Laufstrecke zu betrachten.

Verfahren wird nach dem in Bild 4 dargestellten Prinzip. Wesentlich ist, dass man die beobachteten Gutlaufzeiten jeweils mit einer eigens simulierten jährlichen Laufleistung multiplizieren muss, damit man die Rechtszensurierungen in einer einheitlichen Laufstreckeneinheit verfügbar hat. Diese Rechtszensurierungen werden mit den beobachteten Lebensdauern in derselben Laufstreckeneinheit zu einer rechtszensierten Stichprobe verbunden und daraus eine Lebensdauerverteilung bezüglich der Laufstreckeneinheit geschätzt. Dieses kann durch eine Kaplan-Meier-Schätzung oder eine Maximum-Likelihood-Schätzung bewerkstelligt werden.

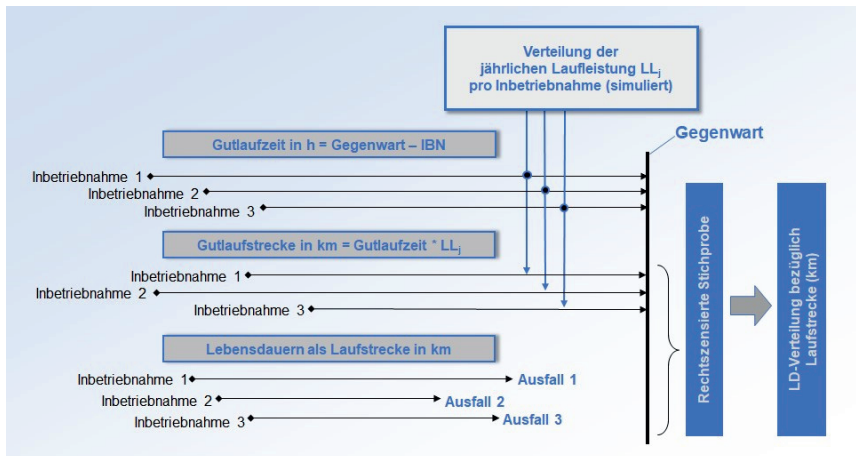


Bild 4: Bestimmung der Lebensdauerverteilung bezüglich der Laufstrecke

Bei der Bereitstellung der Gutlaufzeiten sind möglicherweise einige Besonderheiten zu beachten, wie einer nur ungenau angegebenen Produktionszeit oder einer Verzögerung zwischen Produktion und Inbetriebnahme.

Durch die Einrechnung einer simulierten jährlichen Laufleistung ist das konkrete Ergebnis der Gutlaufstrecke etwas Zufälliges und nicht in seiner Einzelbewertung interpretierbar. Erst durch die Vielzahl der berechneten Gutlaufstrecken stellt sich ein Gesamtbild ein, dass sich auch bei Wiederholungen ähnlich einstellen würde.

## Schritt 2

Ausgehend von einem Gutläufer, der in einer Zeiteinheit gegeben ist, wird durch Multiplikation mit einer simulierten Jahreslaufleistung eine entsprechende Gutlaufstrecke abgeleitet. Diese absolvierte Laufstrecke kann als Voralterung verstanden werden und findet ihren Einfluss bei der Ableitung der Restlebensdauer in Längeneinheiten. Dabei lässt sich die Verteilung der Restlebensdauer aus der Verteilung der Lebensdauer bezüglich der Laufstrecke bestimmen. Mit der bekannten Restlebensdauerverteilung kann man eine Restlebensdauer simulieren, was zu einem Ausfallpunkt gemessen in Längeneinheiten führt. Die Rückführung dieses Ausfallpunktes in einen zeitbemessenen Ausfallpunkt erfolgt über die zuvor bereits verwendete jährliche Laufleistung. Als Resultat erhält man eine zeitbemessene Lebensdauer, die nach Addition zur Inbetriebnahme in ein Zeitraster eingeordnet werden kann. Dieses Vorgehen ist in Bild 5 dargestellt.

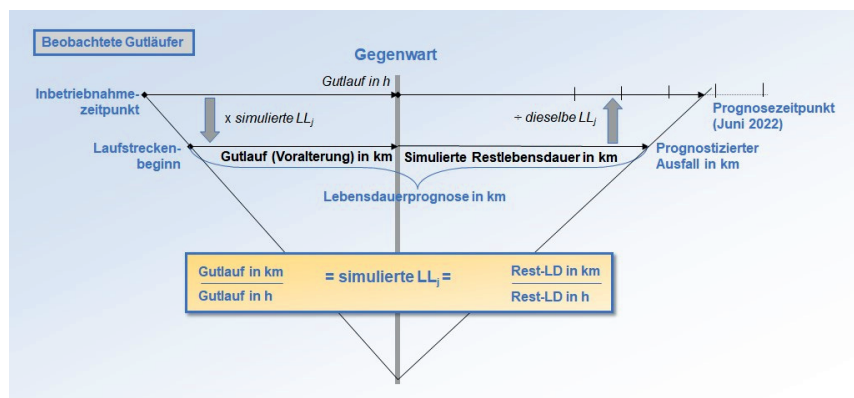


Bild 5: Vorhersage der Ausfälle zu den Gutläufern

Auch hier gilt, dass die einzeln simulierten Ausfallzeitpunkte nicht interpretierbar sind. Erst die „Masse“ führt zu einem stabilen Verteilungsbild über dem Zeitraster.

## Schritt 3

Schließlich sind noch jene Einheiten zu betrachten, deren Inbetriebnahme im Prognosezeitraum stattfinden und bis Ende des Prognosezeitraumes ausfallen können. Das Prognoseprinzip ist in Bild 6 beschrieben.

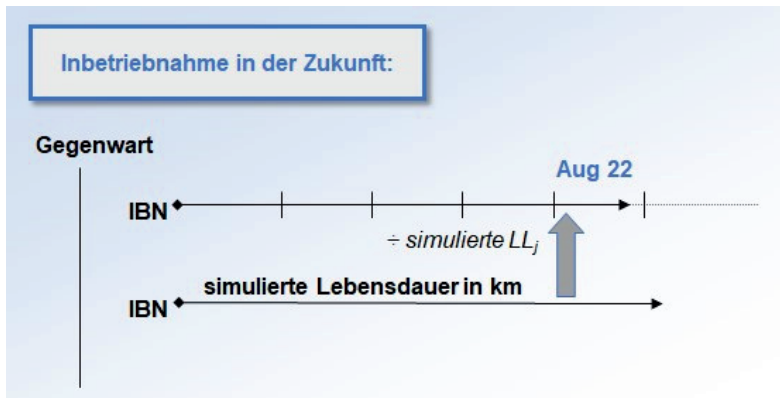


Bild 6: Vorhersage der Ausfälle für in der Zukunft produzierte Betrachtungseinheiten

Es wird eine Lebensdauer mit Hilfe der in Schritt 1 geschätzten Lebensdauerverteilung simuliert. Dann folgt eine Umrechnung mit Hilfe einer ebenfalls simulierten jährlichen Laufleistung. Als Ergebnis erhält man eine Lebensdauer in einer Zeiteinheit. Addiert man diese zur Inbetriebnahme hinzu, erhält man den Ausfallzeitpunkt und kann diesen in ein Zeitraster einordnen. Auch hier gilt: Erst durch Vielzahl der prognostizierten Ausfälle ergibt sich ein stabiles Bild.

#### Schritt 4

Aus den Schritten 2 und 3, sowie der Einordnung der tatsächlich beobachteten Ausfälle erhält man pro Zeitintervall im Zeitraster eine bestimmte Ausfallanzahl.

#### Schritt 5

Wiederholt man die Schritte 2-4, so wird man feststellen, dass die Anzahlen innerhalb der Intervalle bis zur Gegenwart stets die gleichen sind. Dagegen variieren die Anzahlen in den Intervallen im Prognosebereich (siehe Bild 7).




Bild 7: Beobachtete und prognostizierte Ausfallanzahlen pro Quartal

Das ist natürlich auch das, was man von einer Prognose erwartet. Sie zeigt zunächst nur auf, was passieren könnte. Eine verwertbare Aussage erhält man erst, wenn man durch viele Simulationsläufe mehrere Prognosen erzeugt. Erst dann ist die Berechnung statistischer Kenngrößen möglich und vor allem können sogenannte Konfidenzbereiche angegeben werden. Ein Beispiel für eine entsprechende Aussage ist die folgende:

„Die Anzahl der Ausfälle im Monat Mai 2022 beträgt mit Sicherheit 60% zwischen 2 und 4“. Allgemein ist einzuschätzen, dass damit fundierte Bewertungen und Entscheidungen möglich gemacht werden. Einsatzbereiche können die Ressourcenplanung (Ersatzteile, Kostenprognose) und die Einschätzung von Kenngrößen wie beispielsweise der Fehlerhäufigkeit oder der Verfügbarkeit sein.

Natürlich soll nicht der Eindruck erweckt werden, dass man beliebig genaue Prognosen mit einer beliebig hohen Sicherheit treffen kann. Eine gewisse Zufälligkeit liegt in der Natur der Sache.

Bild 8 zeigt eine beispielhafte Prognose von Ausfallanzahlen mit Konfidenzbereichen.




Bild 8: Beobachtete Ausfallanzahlen und statistische Beschreibung der prognostizierten Ausfallanzahlen

## 6. Fazit

Die vorgestellte Methode eignet sich, um eine Vorhersage von Ausfallanzahlen zu treffen. Vorauszusetzen ist, dass man Informationen zu den Ausfällen und Gutläufern aus einem Beobachtungsbereich kennt und die Produktionszahlen sowohl für den Beobachtungsbereich als auch den Prognosebereich vorzuliegen hat. Außerdem benötigt man die Verteilung der jährlichen Laufleistungen. Die Prognosen können in Form von Konfidenzbereichen getroffen werden. Damit besteht die Möglichkeit, weiterführende Ressourcenplanungen durchzuführen. Dazu gehören die anfallenden Garantiekosten und die Abschätzung des Instandhaltungsaufwandes.



# Berücksichtigung menschlicher Zuverlässigkeit in der Gestaltung autonomer Systeme

Prof. Dr. habil. **Oliver Sträter**, Arbeits- und Organisationspsychologie, Fachbereich Maschinenbau, Universität Kassel

## 1 Kurzfassung

An vielen Stellen in der technischen Entwicklung entstehen derzeit autonome Systeme, welche den Menschen in seinen Tätigkeiten unterstützen oder gar ersetzen sollen. Die Erwartungshaltung für diese Entwicklungen ist, dass die Tätigkeiten dadurch schneller und besser oder auch sicherer durchgeführt werden können. Typische Beispiele sind das autonome Fahren, von dem man sich eine Erhöhung der Verkehrssicherheit verspricht, oder die Mensch-Roboter-Kollaboration in der Montage- und Fertigungsindustrie.

Autonome Systeme können jedoch durchaus auch negative Auswirkungen haben, wie aus Industrien bekannt sind, die bereits einen hohen Automationsgrad erreicht haben. Dies sind klassischerweise Prozesstechnik und hier insbesondere die Kerntechnik oder die Luftfahrt.

Aus der Perspektive der menschlichen Zuverlässigkeit stellt sich die Frage, welche Bedingungen erfüllt sein müssen, damit das entstehende Mensch-Automat System zuverlässig agieren kann. Hierzu hat der Fachausschuss 504 „Menschliche Zuverlässigkeit und Sicherheit“ eine Expertenempfehlung aufgestellt. Sie beschreibt die bekannten und zu erwartenden Wechselwirkungen zwischen Mensch und Automaten sowie wichtige Voraussetzungen für das zuverlässige Gelingen einer Kollaboration zwischen Mensch und Automat (VDI-EE, 2021).

Eine wichtige Voraussetzung zur Vermeidung automations-bedingter Unfälle, ist, dass in der Systemgestaltung autonomer Systeme die menschliche Zuverlässigkeit korrekt und umfassend betrachtet wird und Sicherheitsbeiträge von Mensch und Technik so analysiert und bewertet werden, dass ein sichereres Gesamt-System entstehen kann. Dieser Beitrag empfiehlt deshalb, die Sicherheitsbewertung autonomer Systeme anhand der VDI-4006 Blatt 2 durchzuführen und die Expertenempfehlung zur Auslegung autonomer Systeme zu berücksichtigen (VDI 4006-2, 2017).

Dieser Beitrag zeigt in Ergänzung Beispiele der Gestaltung einer gemeinsamen Betrachtung von technischer und menschlicher Zuverlässigkeit auf und schlägt einen Integrierten System Controller (ISC) zur Lösung typischer automationsbedingter Sicherheitsprobleme vor, welcher autonome und menschliche Sicherheitsbeiträge komplementiert.

## 2 Mensch und Automation

Die Historie der Automation beginnt nicht erst mit dem Zeitalter der Digitalisierung. Menschen sind seit Anbeginn der Menschheit bemüht, beschwerliche oder monotone Tätigkeiten durch Automaten zu ersetzen. Klassische Beispiele sind das Mühlrad oder Bewässerungssysteme. In der neueren industriellen Entwicklung sind komplexe hochautomatisierte Systeme entstanden. Klassisches Beispiel ist eine kerntechnische Anlage, deren reibungsloses Systemverhalten und Sicherheit nur durch hochautomatisierte Prozesse gewährleistet ist. Ein weiteres typisches Beispiel ist der Autopilot eines Flugzeuges.

Grundlegendes Systemdesign ist dabei, den Menschen von der Aufgabe zu befreien und ihn nur dann in die Aufgabe zurückzuführen, wenn der Automat nicht mehr in der Lage ist, die Aufgabe durchzuführen. Dies kann durch einen technischen Defekt bzw. Verschleiß erforderlich werden oder dadurch, dass sich die Aufgabenanforderungen ändern und der Automat nicht mehr in der Lage ist, diese Aufgabe durchzuführen. Dieser Fall wird auslegungsüberschreitender Bereich genannt.

*Eines der bekanntesten Beispiele für einen Unfall im auslegungsüberschreitenden Bereich ist der Verlust einer Air France Maschine über dem Atlantik. Durch heftigen Eisregen fielen mehrere Pitot-Sonden aus, wahrscheinlich durch Verstopfung durch Eiskristalle eines heftigen Eisregens. Diese Sonden sind redundant ausgelegt und steuern den Autopiloten an. Im auslegungsgemäßen Betrieb darf durchaus eine dieser Pitot-Sonden verreisen und ausfallen; es ist jedoch in der Auslegung nicht vorgesehen gewesen, den Mehrfachausfall der Pitot-Sonden abzudecken, da ein derart heftiger Eisregen, der mehrere Sonden verreis, als ein sehr unwahrscheinliches Ereignis eingestuft wurde ([https://de.wikipedia.org/wiki/Air-France-Flug\\_447](https://de.wikipedia.org/wiki/Air-France-Flug_447); Schmid, 2012).*

### 2.1 Klassischer Gestaltungsansatz: Mensch oder Automation

Der Mensch wird durch die Automation in die Rolle eines Überwachers des Systems versetzt und das technische System arbeitet autonom vor sich hin. Damit Unfälle wie der Air France Flug 447 nicht geschehen, wird versucht, den Funktionsumfang des autonomen Systems immer mehr zu erweitern und die auslegungsüberschreitenden Bereiche zu minimieren. Eine absolute Autonomie wird hierdurch nicht erreicht werden können, denn bei der Gestaltung eines technischen Systems kann nie der gesamte Funktionsumfang technisch umgesetzt werden (aus Kosten und Aufwandsgründen) und es wird immer auslegungsüberschreitende Bereiche geben. Der Mensch wird so immer weiter in die Rolle des Überwachers versetzt.

Bild 1 zeigt diesen Gestaltungsansatz. Eine vormals aktiv vom Menschen durchzuführende Aufgabe (oberer Teil der Bild) wird durch einen Regler ersetzt und der Mensch muss sich nur zuschalten, wenn die Automatik nicht wie vorhergesehen funktioniert (vgl. Sträter, 2019a; VDI 4006-1, 2015).

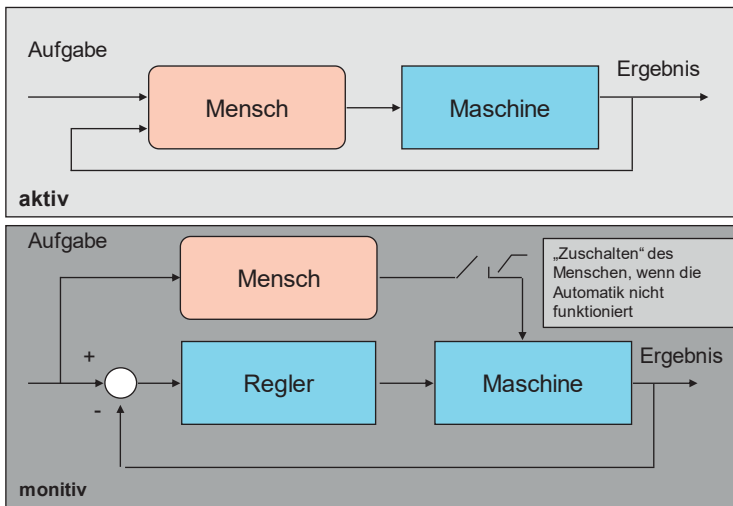


Bild 1: Klassische Gestaltungsphilosophie von Mensch und Automation.

Aus diesen Gestaltungsansatz ergeben sich eine Reihe von menschlichen Problematiken, die Bainbridge (1987) bereits als die sogenannten drei Ironien der Automatisierung zusammengefasst hat:

1. Hohe Automatisierung führt zunächst prinzipiell zu weniger Handmaßnahmen des Menschen. Er wird aus den Regelkreis herausgenommen (out of the loop). Hierdurch ist der Mensch weniger geübt und seine motorischen Fertigkeiten mit der Technik umzugehen (manual skills) nehmen ab. Gleiches gilt für seine kognitiven Fertigkeiten (cognitive skills), da er sich nicht mehr mit der Technik des Systems auseinandersetzen muss. Im weiteren Verlauf wird dadurch sein Zugriff auf Wissen erschwert, kein neues Wissen über das Verhalten des Prozesses erlernt und das Wissen um Problemlösungen verkommt zunehmend. Insgesamt verschlechtern sich hierdurch seine Fähigkeiten, den Prozess bei Ausfall der Automatik zu übernehmen.

2. Ein störungsfrei ablaufender Prozess bedeutet für den Menschen nur vermeintlich eine Arbeitsentlastung. Tatsächlich handelt es sich um eine Zusatzaufgabe für den Menschen, denn er ist in der Rolle des Überwachers des technischen Systems und muss permanent und dauerhaft diese Überwachungsaufgaben leisten. Beispiele sind Piloten, die das fehlerfreie Funktionieren des Autopiloten überwachen müssen oder Fahrzeugführer die ein autonom fahrendes Fahrzeug überwachen müssen. Diese vermeintlich einfache Aufgabe führt jedoch zu Vigilanzproblemen (Monotonie, Müdigkeit) und stellt für den Menschen nicht nur eine zusätzliche, sondern auch eine schwer erkennbare Aufgabe dar (woran erkenne ich, dass der Automat nicht mehr richtig funktioniert?).
3. Eine Störung des Automaten erfordert die Übernahme (take over) der Prozesskontrolle durch den Menschen. Hierzu muss sich der Mensch in das Ereignis und Auswahlzenario des Automaten hineinendenken. Erschwerend ist dabei, dass Rückmeldungen in hoch automatisierten Systemen meist nur auf der funktionalen Ebene der automatischen Systeme vorgesehen sind und Detailkenntnisse über das Schadensszenario damit für den Menschen unbekannt sind. Er muss also mit unzureichender Information entscheiden und agieren und auf Basis von Vermutungen Handlungen zur Vermeidung kritischer Ereignisse generieren.

Insgesamt kommt Bainbridge zu dem Schluss, dass nicht davon ausgegangen werden kann, dass hohe Automatisierung die Prozesssteuerung für den Menschen vereinfacht und weniger Training des Menschen erforderlich ist. Unfälle zeigen dies eindeutig.

Systemgestalter gehen bei der sicherheitstechnischen Auslegung eines Automaten davon aus, dass der Mensch dauerhaft das korrekte Funktionieren des Automaten überwacht, sich also in einem aufgabenorientierten Modus befindet. Durch das Herausnehmen des Menschen aus dem Regelkreis geschieht hinsichtlich der Zuverlässigkeit jedoch ein wichtiger Effekt: Solange der Automat fehlerfrei funktioniert und der Mensch im Überwachungs-Modus ist, wird er sich andere Aufgaben suchen, um seine Aktivität aufrechtzuerhalten. Er wird sich also andere Ziele im Arbeitssystem suchen. Der Fahrer eines autonom fahrenden Fahrzeugs wird also beispielsweise nicht mehr dauerhaft auf die Straße schauen, sondern sich andere Betätigungsfelder im Fahrzeug suchen (VDI-EE, 2021).

Bei der aufgabenbezogenen Bewertung wird davon ausgegangen, dass die Aufgabenstellung und die Art und Weise, wie diese abzuarbeiten ist (Handlungsabfolge), dem Menschen bekannt ist. Es handelt es sich also um Tätigkeiten des Menschen, die auf der Basis von bekannten Routinen oder vorgegebenen Anweisung abgearbeitet werden. Eine Entscheidung, ob bzw. welche Tätigkeit auszuführen ist, ist nicht mehr erforderlich. Die zielbezogene Sichtweise berücksichtigt die im Zuge der Aufgabenerledigung erforderlichen Entscheidungsprozesse.

Die zielbezogene Sichtweise berücksichtigt, dass eine Person zunächst verschiedene Alternativen auf Basis von eigenen Zielen und Zielen der Organisation mit den gegebenen Störungen abgleichen und bewerten muss, um die aus der eigenen Sicht optimale Handlung zu generieren. Bei solchen Abgleichprozessen können Fehlentscheidungen getroffen werden, die dazu führen, dass eine Handlung durchgeführt wird, welche nicht optimal für die Sicherheit des Systems ist und möglicherweise negative Auswirkungen auf die Sicherheitsleistung des Systems hat (Sträter, 2019b).

Der Unterschied zwischen aufgaben- und zielbezogenen Verhalten hat drastische Auswirkungen auf die Bewertung der menschlichen Zuverlässigkeit. Wohingegen aufgabenbezogenes Verhalten Zuverlässigkeit und von ca.  $P=1 \cdot 10^{-3}$  erreichen kann, gelingt im zielorientierten Modus allenfalls eine Zuverlässigkeit von ca.  $P=1 \cdot 10^{-1}$  (siehe VDI 4006-2; Sträter, 2019b). In autonomen Systemen wird vom Menschen, der auf der operativen Ebene eingesetzt wird, verlangt, aufgabenorientiert zu agieren und mögliche technische Fehler oder Anwendungsgrenzen des autonomen Systems abzufangen. Allerdings ist genau für diese Situation zielbezogenes Verhalten zu unterstellen. Dies bedeutet, dass Sicherheitsanalysen, die auf der operativen Ebene in autonomen Systemen aufgabenbezogenes Verhalten unterstellen, eine Fehlbewertung ca. um den Faktor 100 vornehmen.

Unfälle zeigen diese Fehlbewertung auf. Bezogen auf die Wechselwirkung von Menschen Automation zeigen sich in Unfällen nicht Handlungs-Unzuverlässigkeiten auf der menschlichen Seite, sondern Defizite in der Abstimmung von Eigenschaften des Menschen mit den Eigenschaften des Automaten (Sträter, 2019a).

Sicherheitstechnisch wird ein System also immer dann unzuverlässiger, wenn das autonome System nicht in der Lage ist in der gegebenen Situation sicherheitsgerichtet zu agieren (Ausfall oder auslegungsüberschreitende Situation) und gleichzeitig der Mensch im zielorientierten Modus im System agiert. Deshalb ist gerade bei Ausfall von sehr gut aber nicht 100-prozentig funktionierenden Automaten, in denen zielorientiertes Verhalten des Menschen sehr wahrscheinlich ist, von einer Erhöhung des Risikos bei Ausfall des Automaten auszugehen (VDI-EE, 2021).

Grundproblem in der Gestaltung ist die monitive Verschaltung des Menschen mit dem Automaten (Bild 1 unten). Hierdurch verliert man de facto im auslegungsüberschreitenden Bereich den Zuverlässigkeitsbeitrag des Menschen.

## 2.2 Sind Zusatzaufgaben und Gameification die Lösung?

Dieses Problem ist nicht neu und wird seit Anbeginn der Forschung zum Thema Mensch-Automation Wechselwirkung diskutiert. Das naheliegendste Konzept, ohne den Gestaltungsansatz insgesamt infrage zu stellen, ist, den Menschen durch andere Aufgaben zu beschäftigen. Auch aus betriebswirtschaftlicher Sicht erscheint dies durchaus attraktiv. Da ein Pilot lediglich überwachen muss, ob der Autopilot fehlerfrei agiert, könnte er in dieser Zeit andere Tätigkeiten durchführen, die die Produktivität steigern. Beispielsweise könnte er Flugsicherungsaufgaben übernehmen. Ein ähnliches Konzept verfolgt der Gameification-Ansatz, der Anreize schafft, bestimmte andere Tätigkeiten durchzuführen, während der Automat aktiv ist.

Die Ansätze halten den Menschen nicht im Loop. Sie beugen jedoch zumindest Monotonie-Erscheinungen vor und dienen so also eher dazu, typische Probleme der Wachsamkeit des Menschen als Systemüberwacher zu vermeiden.

Sowohl Zusatzaufgaben als auch der Gameification-Ansatz erzeugen jedoch Zielkonflikte für die handelnde Person, die damit unweigerlich in einen Zielkonflikt zwischen der Zusatzaufgabe/Gameification-Aufgabe und der eigentlichen Überwachungsaufgabe gerät. Im Sinne der oben besprochenen Ironien der Automatisierung handelt es sich hiermit also um eine Zusatzaufgabe, die zielorientiertes Verhalten indiziert. Gerade bei sicherheitsgerichteten Aufgaben ist dieser damit Ansatz ungeeignet, denn es wird zielorientiertes Verhalten generiert und damit der Zuverlässigkeitsbeitrag des Menschen bei Ausfall des Automaten reduziert.

Ziel muss es sein, den Menschen im Loop zu halten, also nicht eine weitere Arbeitsaufgabe zuzuteilen, die dann in Konflikt mit der primären Aufgabe steht, sondern ihn in der Aufgabe mit seinen Eigenschaften und Fähigkeiten zu belassen oder diese in Idealfall mit dem Automaten zu teilen.

## 3 Beispiele gelungener Integration menschlicher Eigenschaften und automatischer Fähigkeiten

Ziel einer gemeinsamen Gestaltung von Mensch und Automat muss eine bessere Abstimmung bzw. eine sich ergänzende Herangehensweise der Gestaltung sein. Es gibt Gestaltungslösungen im Bereich der Halbautomation, die als gute Beispiele dienen können, wie eine solche Integration stattfinden kann und der Zuverlässigkeitsbeitrag des Menschen in autonomen Systemen aufrechterhalten werden kann. Im Folgenden werden typische Beispiele solcher gelungenen Integrationen menschlicher Eigenschaften und automatischer Fähigkeiten vorgestellt.



Die Flächenanteile ändern sich dynamisch abhängig von der Druck- und Temperatursituation und anderen Parametern im Kraftwerk (grüne, gelbe und rote Fläche wird größer oder kleiner, abhängig von unterschiedlichen Betriebsparametern).

Durch ein solches Diagramm können Automatik und Mensch die komplexe Anfahr-Prozedur eines Kernkraftwerkes gemeinsam lösen. Der Mensch erkennt in dem Display sofort, ob das automatische System den Betriebspunkt im grünen Bereich hält und weiß sofort, was zu tun ist, wenn Temperatur oder Druck zu schnell oder zu langsam steigen. Der Mensch „fährt“ die Anlage durch den grünen Parcours und wird dabei von der Automatik unterstützt. Mensch und Automation agieren gemeinsam und die menschlichen Fähigkeiten und Fertigkeiten werden kontinuierlich eingesetzt. Es entsteht kein monitives Verhalten, Vigilanz-Problematiken oder Probleme bei der Übernahme, falls die Automatik versagt.

### 3.2 Flight Envelope

Vergleichbar zu der komplexen Regelungsaufgabe eines Kernkraftwerkes ist die von Piloten in Flugzeugen. Der Pilot erfüllt hier eine wesentliche Sicherheitsaufgabe und muss im Falle von Systemausfällen schnell und richtig reagieren. Aus dem Grunde ist es ideal, wenn der Pilot immer im Regelungs-Loop verbleibt. Gelingt hier eine Übergabe nicht, führt dies sofort zu schwerwiegenden Unfällen, wie dem Verlust der Air France 447 über dem Atlantik (Schmid, 2012). Auf der anderen Seite sind die komplexen Regelungsaufgaben des Fliegens nicht nur manuell durchführbar.

Wie beides zu gewährleisten ist, zeigt das Konzept des Flight-Envelopes (<https://de.wikipedia.org/wiki/Flugenveloppe>). Bild 3 zeigt die Logik des Flight-Envelope.






Bild 3: Logik des Flight-Envelope (grün: fiktives Überschallflugzeug, schwarz: Unterschallflugzeug) (Quelle: <https://de.wikipedia.org/wiki/Flugumhulle>).

Der Flight-Envelope definiert das Sicherheitsfenster, in dem entweder der Automat oder der Mensch (Pilot) das Flugzeug regeln darf. Nur wenn Pilot oder Automat im Begriff sind, diesen Flight-Envelope zu verlassen, werden Warnungen ausgegeben oder Sicherungssysteme in Gang gesetzt.

Im Rahmen der Regelung darf sich sowohl die Automatik als der Pilot in der Fläche des Flight-Envelope frei bewegen. Das Flugzeug wird in der Luft bleiben und es ist unerheblich, ob die Automatik oder der Mensch die Regelungsaufgabe übernimmt. Das Konzept des Flight-Envelope kann auch auf andere flugdynamische Parameter ohne weiteres übertragen werden und erlaubt so, automatische und menschliche Eingriffe so zu koordinieren, dass eine echte Mensch-Automatik Integration gelingt.

### 3.3 STCA - Short Term Conflict Alert

In der Flugsicherung, die ganz wesentlich auf eine gleichberechtigte sicherheitstechnische Rolle des Menschen und automatischer Systeme setzt, ist eine Integration menschlicher und automatischer Zuverlässigkeit Beiträge essenziell.

Um den Zusammenstoß zweier Flugzeuge zu vermeiden, gibt es als letzte Sicherheitsfunktion das TCAS (Tactical Collision Avoidance System), welches unmittelbar vor einem möglichen Zusammenstoß das Flugmanöver der beiden Flugzeuge automatisch so aushandelt, dass die Flugzeuge ein aufeinander abgestimmtes Ausweichmanöver fliegen können. Das TCAS-System ist jedoch nicht durch-automatisiert; die Piloten müssen den Hinweis des Systems noch manuell durchführen. Das TCAS-System ist hier das letzte Sicherheitsnetz zur Vermeidung des Zusammenstoßes. Damit die Flugzeuge bereits im Vorfeld rechtzeitig auf entsprechende Routen oder Flughöhen verlagert werden können, damit das TCAS-System gar nicht erst ansprechen muss, dient das STCA (Short Term Conflict Alert), es teilt dem Fluglotsen mit, ob in seinem kontrollierten Luftraum Bewegungen stattfinden, die in einem kurzen Zeitfenster das Potenzial für einen sicherheitskritischen Zustand oder gar einen TCAS-Alarm haben. Das STCA wertet dabei Fluggeschwindigkeit, Flugrichtung und Flughöhe aller Flugbewegungen im Sektor permanent aus und warnt den Fluglotsen, wenn eine Staffellungsunterschreitung (bei 5 nm) droht und zeigt an, wieviel Zeit zur Behebung des Konfliktes zur Verfügung steht. Bild 4 zeigt ein solches STCA System. Im großen Fenster sind zwei in Konflikt stehende Flugbewegungen von insgesamt vier Flugzeugen angezeigt (rote und gelbe Callsigns). Im kleinen Fenster links unten wird die Kritikalität des Konfliktes in Abhängigkeit von Zeit und Abstand angezeigt. Je weiter unten links der Konflikt angezeigt wird, desto kritischer ist er und muss behandelt werden. Liegt der Punkt unterhalb der roten gestrichelte Linie handelt es sich um eine Staffellungsunterschreitung.

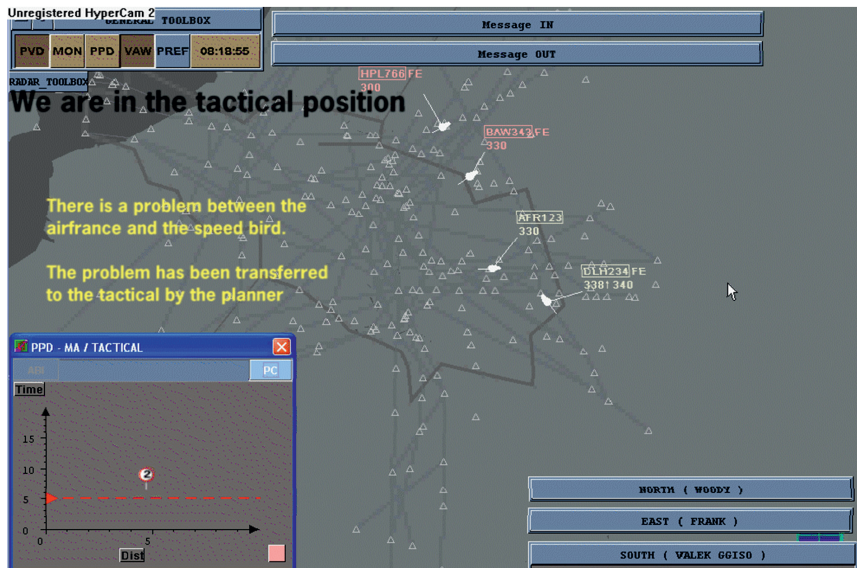


Bild 4: Ansatz des STCA - Short Term Conflict Alert

(Quelle: <https://www.eurocontrol.fr/projects/edep/demo/spd/Tools/STCA/STCA.htm>).

Durch den Einsatz des STCA kann der Fluglotse unmittelbar sehen, wie groß der Handlungsbedarf für ein manuelles Eingreifen ist, um sowohl Staffelungsunterschreitung als auch den möglichen Einsatz des TCAS Systems als letzte Sicherheitsreserve zu vermeiden. Auch wenn in der Luftfahrt die Sicherheitssysteme wie das TCAS-System nicht durchautomatisiert sind und die letztliche Entscheidung für Flugmanöver den Piloten obliegt, ist das STCA ein typisches System, um Sicherheitsreserven auf Seiten der Fluglotsen anzuzeigen und rechtzeitig Handlungsbedarf zu erkennen. Durch das System bleibt der Fluglotse im Loop und hat dennoch ein System, bei komplexen Lufträumen mit vielfältigen Flugbewegungen rechtzeitig kritische Situationen zu erkennen und ihnen entgegenzuwirken.

### 3.4 Aktive Stellteile in der Spurhaltung von Fahrzeugen

Das Zusammenwirken von Mensch und Automat ist gerade beim autonomen Fahren ein viel diskutiertes Gestaltungsproblem. Insbesondere hier ist die Gestaltungsphilosophie Versetzens

des Menschen in einen monitiven Modus und des Zuschaltens des Menschen besonders kritisch, da geringe Sicherheitsreserven vorhanden sind und menschliche Eingriffe bei hoher Dynamik mit einer schnellen Reaktionsgeschwindigkeit geschehen müssen. Insbesondere in den Fällen, in denen autonom fahrende Fahrzeuge mit analogen Fahrzeugen in einem hybriden Verkehrsmix agieren, ist es deshalb zwingend erforderlich, den Menschen im Loop zu halten. Um aufzuzeigen, wie eine gute Mensch-Automation Zusammenarbeit geschehen kann, wurde in Bubb et al. (2015) zum Thema des Spurhaltens beim Autofahren eine enge und weite Führung des Automaten bei der Spurhaltung untersucht (Bild 5). Eine enge Führung bedeutet, dass der Automat wenig Handlungsspielraum für den Menschen zur Verfügung stellt und bei leichten Abweichungen bereits ein Rückstellmoment initiiert. Der Autofahrer fühlt sich in dem Fall so, als wenn er in tiefen Spurrinnen fährt. Jeder Fahrer, der das Fahren in tiefen Spurrinnen schon mal erlebt hat weiß, dass dies sehr unangenehm ist und die Fahrzeugführung als fremdbestimmt und unsicher erfahren wird. Auch kann der Fahrer kaum kleineren Unebenheiten ausweichen und damit hat er keinerlei Entscheidungsgewalt über die Fahrzeugspur.

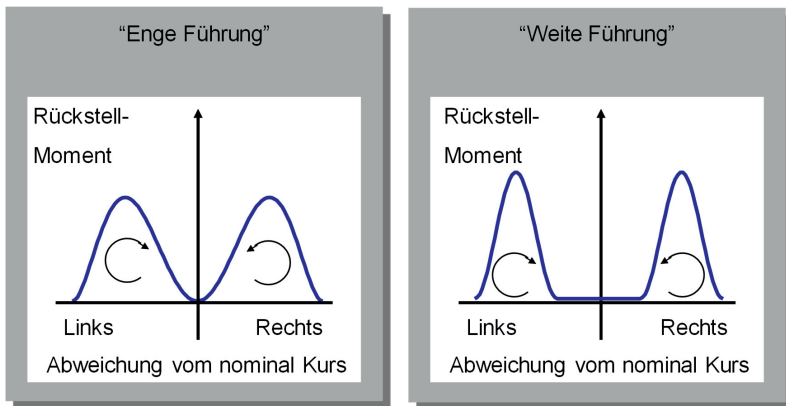


Bild 5: Enge und Weite Führung im Bereich des Spurhaltens beim Autofahren  
(Quelle: nach Penka, 2000; Bubb et al., 2015, p. 546).

Anders sieht es aus, wenn der Automat eine breite Führung zulässt, die nur dann ein Rückstellmoment initiiert, wenn die Spurhaltung einen kritischen Wert (Überschreiten des Sicherheits-Korridors) annimmt. Der Fahrer kann normale Spurhaltetätigkeiten durchführen und der

Automat unterstützt ihn rechtzeitig, wenn die Spurhaltung kritische Werte annimmt. Ein solches fahren wird vom Fahrer sehr positiv erlebt und ist sicherheitstechnisch sogar der engen Spurführung vorzuziehen.

#### 4 Ein integrierter System-Controller

Die unterschiedlichen oben dargestellten Lösungsansätze zeigen, wie ein gemeinsamer Gestaltungsansatz von Mensch und Automat aussehen kann. Ziel der unterschiedlichen Lösungsansätze ist, den Menschen aktiv und im Loop zu halten, Monotonie oder Vigilanz-Erscheinungen zu vermeiden und die automatische Regelung mit menschlichen Fähigkeiten optimal zu integrieren. Bild 6 zeigt die Grundstruktur der sich aus der Diskussion ergebenden allgemeinen Struktur für einen integrierten Gestaltungsansatz zwischen autonomen Systemen und Menschen.

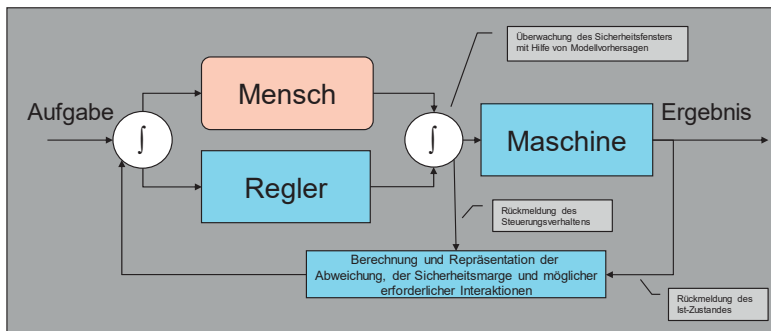


Bild 6: Grundstruktur eines Integrierten System-Controllers (ISC)

Zunächst wird die Aufgabe sowohl dem Menschen als auch dem Regler gestellt (Verteilung hinter Aufgabe). Die erforderlichen Handlungen werden entweder vom Menschen oder vom Regler ausgeführt. Im Summenpunkt vor der Maschine wird überwacht, ob durch eine der Eingaben ein kritisches Sicherheitsfenster für die Maschine beeinträchtigt ist. Ist das nicht der Fall, wird die Eingabe des Menschen an die Maschine weitergegeben. Der Regler assistiert in diesem Fall dem Menschen und nicht umgekehrt. In der Rückmeldungsschleife werden permanent Eingabeimpulse und Ergebnisse miteinander verglichen, deren Abweichung und Bedeutung für die Sicherheitsmarge dem Menschen und dem Regler rückgemeldet und damit erforderliche zukünftige Interaktionen initiiert.

Von der menschlichen Seite vermeidet diese Grundstruktur sowohl Monotonie-Erscheinungen als auch andere negative Effekte von Automation wie der von Brainbridge beschriebene Übungs- bzw. Wissensverlust oder die Orientierungslosigkeit bei Übernahme der Funktion des Automaten bei dessen Ausfall. Ein solcher integrierter System-Controller erlaubt es dem Menschen quasi parallel zum Automaten zu agieren. Er verfällt dadurch nicht in zielorientiertes Verhalten und bleibt als sicherheitstechnische Redundanz im System erhalten. Möglich wird dies durch eine Integration der Eingabeimpulse von Mensch und Regler.

Sicherheitstechnisch entspricht dieser Architektur dem was man aus Rechnerarchitekturen für sicherheitskritische Prozessaufgaben kennt (eine sogenannte eins von zwei Auswahl). Regler und Mensch bilden eine Redundanz zueinander.

## 5 Diskussion

Zusammenfassend ist festzustellen, dass in der Systemgestaltung autonomer Systeme die menschliche Zuverlässigkeit eine entscheidende Rolle spielt und nur dann einen sinnvollen Beitrag zu Gesamt-Zuverlässigkeit leisten kann, wenn der Automationsansatz den Menschen im Loop hält und nicht als Standby-System betrachtet.

Hierzu muss der Ansatz eines integrierten System-Controllers verfolgt werden, bei dem sich die Sicherheitsbeiträge von Mensch und Technik ergänzen. Das Paper zeigte Beispiele solcher integrativen Ansätze auf. Diese Gestaltungslösung bildet aus Sicht der menschlichen Zuverlässigkeit das Optimum aus menschlichen Zuverlässigkeitsbeiträgen und Zuverlässigkeitsbeiträgen des Automaten.

## 6 Literatur

- Bainbridge, L. (1987) The Ironies of Automation. In: Rasmussen, J., Duncan, K. & Leplat, J. (Eds.) New Technology and Human Error. Wiley. London.
- Bubb, H., Bengler, K., Grünen, R., E. & Vollrath, M. (2015) Automobilergonomie. Springer.
- Löhr, K. P., Sturm, J. & Welker, W. (1992) Erleichterte Prozessführung durch den Einsatz des Prozeß-Informationssystems PRISCA in den Konvoi-Anlagen. In VGB Kraftwerkstechnik 72. VGB - Technischer Verein der Großkraftwerksbetreiber. Essen.
- Penka, A. (2000) Vergleichende Untersuchung zu Fahrerassistenzsystemen mit unterschiedlichen aktiven Bedienelementen. Dissertation an der Technischen Universität. München.
- Schmid, J. (2012) Flight AF 447 31 May 2009. How to Improve Safety in Regulated Industries - What Could We Learn From Each Other. European Commission. Luxembourg, 16-17th October 2012.
- Straeter, O. (2019a), Risikofaktor Mensch? – Zuverlässiges Handeln gestalten. Beuth Verlag: Düsseldorf,
- Straeter, O. (2019b). Human Reliability Assessment - State of the Art for Task- and Goal-related Behavior. In P.V. Varde, R. V. Prakash & N. S. Joshi(eds.), Risk Based Technologies. Springer: Berlin, Heidelberg.
- VDI 4006-1 (2015) Menschliche Zuverlässigkeit - Teil 1: Ergonomische Forderungen und Methoden der Bewertung. Beuth-Verlag. Berlin.
- VDI 4006-2 (2017) Menschliche Zuverlässigkeit - Teil 2: Methoden zur quantitativen Bewertung menschlicher Zuverlässigkeit. Beuth-Verlag. Berlin.
- VDI EE (2021) Berücksichtigung menschlicher Zuverlässigkeit in der Gestaltung autonomer Systeme. VDI Expertenempfehlung. Beuth-Verlag. Berlin.





# Ein Ansatz zur Wiederherstellung ausgefallener Hardwarekomponenten in Fail-Operational Architekturen

## Eine Erweiterung von FDIRO

### A Hardware Redundancy-Recovery Approach for Fail-Operational Architectures

#### An FDIRO Add-On

Dipl.-Ing. **T. Kain**, B.Sc., **M. Aguirre Mehlhorn**, B.Sc.,  
Volkswagen AG, Wolfsburg;  
**T. Horeis**, M.Sc., IQZ GmbH, Hamburg;  
**J. Heinrich**, M.Sc., IQZ GmbH, Wuppertal;  
a.o. Univ.-Prof. Dr. techn. **H. Tompits**,  
Technische Universität Wien, Österreich

#### Kurzfassung

Autonome Fahrzeuge, d.h. Fahrzeuge der SAE-Stufen 4 und 5, bestehen zu großen Teilen aus komplex verteilten Systemen, die im Falle eines Fehlers nicht auf eine menschliche Rückfallebene zurückgreifen können. Folglich werden Prozesse benötigt, die Fehler behandeln und somit gefährliche Situationen vermeiden können. Ein fail-operational Ansatz zur Erfüllung dieser Anforderungen ist FDIRO, welcher die eigenständige schrittweise Behandlung von Fehlern ermöglicht. Nachdem von FDIRO ein Fehler erkannt wurde erfolgt dessen Isolierung indem die fehlerhafte Komponente deaktiviert und eine redundante Komponente aktiviert wird. Anschließend führt FDIRO die Wiederherstellung des Redundanzgrades durch. Als letzter Schritt erfolgt eine Optimierung der Systemstruktur. Im aktuellen Entwicklungsstadium beinhaltet FDIRO einen Ansatz zur Wiederherstellung des Redundanzgrades, der die Redundanz von Softwareanwendungen durch das Starten neuer Anwendungsinstanzen wiederherstellen kann. Allerdings ist FDIRO nicht in der Lage, ausgefallene Hardwarekomponenten, wie Recheneinheiten oder Sensoren, wiederherzustellen. Folglich kann nur eine begrenzte Anzahl von Hardwareausfällen toleriert werden, bevor die Mission durch einen Notstopp beendet werden muss.

In diesem Beitrag wird als Add-on von FDIRO der Hardware-Redundanz-Wiederherstellungsansatz HRR eingeführt. Im Falle eines Hardwarefehlers weist FDIRO nach der Durchführung des Isolierungsschritts HRR an, die fehlerhafte Komponente wiederherzustellen. HRR analysiert

den Fehler und bestimmt einen Reparaturplan, der aus einer geordneten Liste von Reparaturansätzen besteht. Im Falle einer erfolgreichen Reaktivierung sorgt FDIRO abschließend für eine kontrollierte Integration der reparierten Hardwareeinheit.

## Abstract

Autonomous vehicles, i.e., vehicles classified as SAE Level 4 and 5, are complex distributed systems which exclude any human takeover action in case of a failure. Consequently, those vehicles have to be equipped with mechanisms that can handle failures to prevent hazardous situations. To address this, in previous work, FDIRO was developed, a fail-operational approach that handles hard- and software faults in a stepwise fashion. After a fault was detected and isolated, by deactivating the faulty component and activating a redundant component, FDIRO performs a redundancy recovery followed by an application-placement optimization. At the current stage of development, FDIRO implements a redundancy-recovery approach that can recover the redundancy of software applications by starting new application instances. However, FDIRO is not capable of recovering failed hardware components like computing nodes or sensors. Consequently, only a limited number of hardware failures can be tolerated before the mission has to be terminated by an emergency stop.

In this paper, we introduce the hardware redundancy-recovery approach HRR, which is an add-on to FDIRO. In case of a hardware fault, after performing the isolation step, FDIRO instructs HRR to recover the faulty component. HRR analyzes the fault and determines a *repair plan*, an ordered list of repair approaches. In case of a successful reactivation, FDIRO ensures a controlled integration of the repaired hardware.

## 1. Introduction

The development of automated and autonomous driving functions at SAE levels 4 and 5 [7] poses many challenges for the automotive industry. One major challenge is replacing the driver as a controller of the operation of the vehicle. In an autonomous vehicle, the system has to handle failures of functions and components autonomously [4], i.e., the system has to be fail-operational.

The system must react to failures by isolating the faulty component and switching to a fallback configuration that can continue the driving task. After a successful switchover, the goal is to restore the original system state or an alternative configuration, which meets all system design requirements, so that the operation of the vehicle can be continued safely.

To address these requirements, the fail-operational process FDIRO [3] was developed. FDIRO performs a series of steps after the occurrence of a failure in order to restore the system. At the current stage of development, FDIRO is able to recover failed software components but lacks a hardware-repair behavior. As a consequence, hardware faults significantly degrade the reliability of the system. In many cases, hardware failures are not irreparable, e.g., a sensor failure can be, for instance, caused by external factors like dirt or internal events like load peaks. Thus it is conceivable to reactivate the failed components by performing certain repair actions.

In this paper, we investigate the effects of reactivating failed hardware components during runtime. As a motivation for our approach, we first show that performing repair actions during runtime improves the reliability of the system. Afterwards, we introduce the hardware redundancy-recovery approach HRR, which attempts to repair hardware components after they failed during runtime autonomously. Furthermore, we illustrate how the HRR approach can be included in the existing FDIRO procedure.

The idea of HRR is to first analyze the error that caused the failure. Based on this analysis, an ordered list of repair actions is determined, whereby the repair actions are defined and ranked at design time by the system engineer. After the execution of a repair action, the HRR procedure checks whether the fault was fixed. If this is the case, the repaired hardware component can again be used by the system. Otherwise, a subsequent repair action is executed.

To the best of our knowledge, no general hardware repair approach like the one presented in this paper exists. However, some strategies focusing on hardware maintenance have been defined in the past, discussed in what follows.

To begin with, Raghavaiah and Hariprasad [6] specified the following four maintenance strategies used for mechanical equipment: (i) breakdown maintenance, (ii) preventive (scheduled) maintenance, (iii) predictive maintenance, and (iv) reliability-centered maintenance. While breakdown maintenance is a reactive maintenance process that fixes components after their failure, preventive maintenance repairs the component after predefined time intervals to prevent failure and extend the lifetime of the components. Predictive maintenance tries to predict the failure occurrence time by monitoring the components to fix the component before the failure occurs. Reliability-centered maintenance is a process, which analyzes all possible failure modes to customize an individual maintenance plan for each component.

Qin and Li [5] defined a preventive maintenance process with a Markov decision process to determine different reliability parameters. The model can consider systems with several degraded states and preventive maintenance actions between the different states. Even though maintenance always assumes downtime to execute the maintenance actions, this model can

consider a repair behavior of hardware components by using degraded states and their transitions. However, the preventive maintenance actions are modeled using a constant repair rate, and the actions are not further specified or modeled.

Selcuk [8] defines some main future research areas for predictive maintenance, including e-maintenance, remote maintenance, and management systems. While e-maintenance extends the predictive maintenance techniques with monitoring and prognostic functions over the internet, remote maintenance and management systems are aiming to restore the system from a distance. The focus of predictive maintenance lies within intelligent predictions of possible failures rather than intelligent maintenance. However, the authors mentioned promising fields that are focusing on the automation of the maintenance process.

Note that none of these strategies, models, and ideas consider a hardware-repair behavior that is executed during the operation of the vehicles.

The paper is organized as follows: In Section 2, we describe the FDIRO process in its current form. Section 3 shows that implementing a hardware-repair behavior can increase the reliability of autonomous vehicles. In Section 4, we introduce the HRR approach. Furthermore, we illustrate the integration of HRR into FDIRO and provide an example use-case. Section 5 concludes the paper with a brief summary and an outline for future work.

## 2. FDIRO: A Fail-Operational Approach for Autonomous Vehicles

FDIRO [3], standing for “Fault Detection, Isolation, Recovery, and Optimization”, is a fail-operational approach that is specifically designed for the use-case of autonomous driving. The idea of FDIRO is to handle occurring faults in a stepwise manner, as illustrated in Fig. 1.




Fig. 1: Simplified representation of the FDIRO activities.

The first step defines the detection of the fault. Therefore, so-called *monitors* observe the hardware and software applications of the self-driving system. In case a monitor detects a fault, it reports this fault to the *switchover component*. This component isolates the fault by deactivating the faulty software applications. Note that, in case a monitor reports a hardware fault, all

software applications executed by this hardware are considered faulty. Next, the switchover component activates redundant software applications that take over the tasks of the failed applications. If such redundant applications do not exist, the consequences of the fault have to be evaluated. In case this evaluation predicts severe consequences, the *failover controller* takes over the control of the system and brings the vehicle to a stop.

After the isolation of the faulty component and the activation of a redundant component, the *redundancy-recovery component* aims to restore the software-redundancy level. Therefore, the redundancy-recovery component tries to find hardware components that offer enough free resources to run redundant applications.

In the last step, the *placement optimizer* tries to find an optimized application placement that suits the current driving situation.

### 3. Effects of a Hardware-Repair Behavior

Due to the technological capabilities of autonomous vehicles, it is conceivable that those vehicles take measures to repair failed hardware components during operation. For instance, if the visibility of a sensor is compromised by dirt or ice, the vehicle may activate the cleaning or heating unit, respectively, to reactivate the sensor. In case that the system architecture is designed such that another sensor can compensate for the sensor fault during the repair process, it is assumed that the reliability of the system can be improved.

In this section, we investigate the effects of a hardware-repair behavior using AT-CARS [2], a tool to analyze the reliability of a system. AT-CARS allows modeling the software and hardware components of a given system architecture. Furthermore, for each component, a failure rate can be specified. Additionally, AT-CARS also allows defining repair rates for hardware components, i.e., the probability that a hardware component can be repaired after it failed.

Based on the defined failure rates, AT-CARS injects failures into the software and hardware components of the system architecture. After a failure has been injected, the steps specified by FDIRO are executed. AT-CARS evaluates for each occurring failure its effects on system reliability. As AT-CARS is based on a Monte Carlo simulation, many iterations are required to get reliable output values.

The system architecture, illustrated in Fig. 2, that we used to investigate the effects of a hardware-repair behavior is based on the sensor setup as presented by nuTonomy [1]. Furthermore, we added two computing nodes, whereby each computing node is executing three applications, which in turn are arranged redundantly. Each application is once executed in the so-called *active state* and redundantly in the *active-hot state*. Note that since our goal is to investigate the effects of a hardware-repair behavior, a realistic software stack is not required.

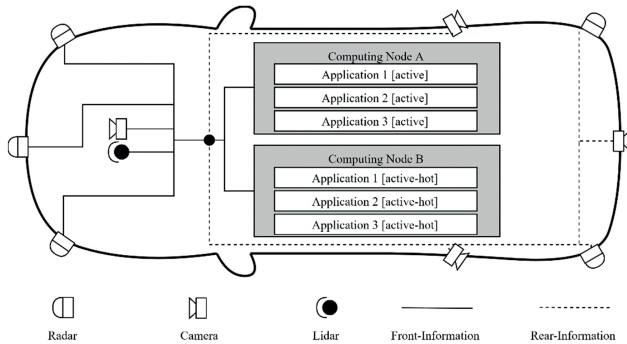


Fig. 2: System architecture used for evaluating the effects of a hardware-repair behavior.

For the sensors, we assume a failure rate of  $5 \cdot 10^{-5}$  failures/hour and for the computing nodes a failure rate of  $10^{-5}$ . Furthermore, we divided the sensors into two groups: front sensors and rear sensors. We define that at least four sensors from each of these two groups must be fully functional for the safe operation of the vehicle. Furthermore, we define that at least one instance of each application has to be executed by the system. However, since in this example we focus on the hardware-repair behavior, we set the failure rate of the software to 0 failures/hour.

To show the effects of a hardware-repair behavior, we evaluated the system architecture using different repair probabilities, whereby we assumed in each simulation run the same repair probability for all sensors and computing nodes. The probabilities vary between 0%, 5%, 10%, 30%, 50%, and 100%. As can be seen in Fig. 3, the reliability of the system increases as the repair probability increases. This example shows that even small repair probabilities can increase the system reliability.




Fig. 3: Evaluation of the effects of different repair probabilities on the system reliability.

#### 4. HRR: A Hardware-Redundancy Recovery Approach

The previous section illustrated that integrating a hardware-repair behavior into FDIRO can improve the system reliability. As the traditional FDIRO procedure does not include a hardware-repair behavior, we introduce in this section the hardware-redundancy recovery approach HRR, which is an extension to FDIRO.

In what follows, we describe the HRR procedure as well as its integration into FDIRO. Furthermore, we provide a use-case to illustrate the introduced procedure.

##### 4.1 Approach Overview

The procedure of the hardware-redundancy recovery approach is executed by the so-called *HRR component*. As illustrated in Fig. 4, the HRR component first analyses the *error report*, i.e., a report created by the monitor in which the hardware component under investigation has been classified as malfunctioning. Based on that error report, the HRR component determines a so-called *fault category*. The latter contains a pre-sorted list of several faults that might have caused the component under investigation to fail. The faults listed in a fault category can be, for instance, ranked using an FMEA-like (“failure mode and effects analysis”) approach [9]. The idea is that for each fault  $f$ , its severity,  $S(f)$ , probability of occurrence,  $O(f)$ , and probability of detection,  $D(f)$ , is determined at design time by the system engineer. The values of those parameters are bounded between 1 and 10, whereby 1 is considered insignificant/unlikely, and 10 corresponds to very significant/probable. By multiplying those three parameters, the so-called *risk-priority number*,  $RPN(f)$ , is calculated:

$$RPN(f) = S(f) \cdot O(f) \cdot D(f).$$

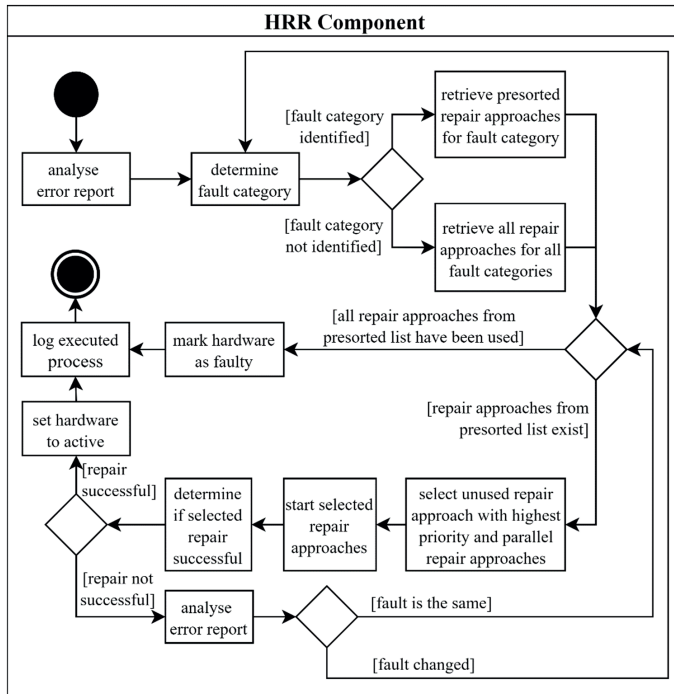


Fig. 4: The activity diagram of the HRR component.

The risk priority number of the individual faults is used to rank them in a descending fashion. Each fault entry of an error category holds a predefined list of so-called *repair approaches*, i.e., approaches to fix the fault that caused the hardware component under investigation to fail. The repair approaches are determined by the system engineer at design time and are ordered hierarchically concerning, for example, their effectiveness, estimated computational effort, and execution time. Furthermore, the system engineer defines which repair approaches can be carried out in parallel.

According to the priority of the corresponding fault, the repair approaches of all faults that are part of the identified error category are sequentially added to the so-called *repair plan*.

In case the HRR component cannot identify a fault category based on the provided error report, the repair approaches of all fault categories of the component under investigation are added to the repair plan.



As the error categories, the faults, and the corresponding repair approaches are determined at design time by the system engineer, they are considered as being *static*. However, using, for instance, an OTA (“over the air”) update mechanism, the set of error categories, faults, and repair approaches can be adjusted.

After the list of repair approaches that might fix the fault is identified, the processing of those approaches starts. The HRR component first selects the approach which is ranked the highest. Additionally, all repair approaches, which can be executed in parallel to that approach, are selected as well. Next, the selected repair approaches are executed. Once all selected repair approaches terminated, the HRR component determines whether the repair was successful. A repair is considered successful if the monitor of the component under investigation does not detect any error. In that case, the hardware component under investigation is set to active and can therefore be again used by the system.

Before the HRR component terminates, the executed procedure, including, for instance, the determined fault category, the executed repair approaches as well as their results, are logged. The logs of several vehicles can then be used to optimize, for example, the prioritization of repair approaches.

In case that the executed repair approaches did not fix the fault, the HRR component determines whether the error report of the monitor still indicates the same fault. If this is the case, the next repair approach in the repair plan that has not been conducted yet is selected. If no more repair approaches that have not been executed yet exist, the hardware component under investigation is marked as *faulty* and can therefore not be used by the system. After logging the executed procedure, the HRR component terminates.

However, in case the analysis of the error report yields a fault that is different from the one determined at the beginning of the HRR procedure, the procedure has to start over.

## 4.2 Integration of the HRR component into FDIRO

At the current stage of development FDIRO is capable, due to its redundancy-recovery component, to recover software applications, but it lacks a procedure to recover hardware. To extend FDIRO towards a fail-operational approach that can recover failed software as well as hardware, we integrate the HRR component into the FDIRO procedure.

As illustrated in Fig. 5, the procedure of the HRR component is initiated by the redundancy-recovery component of FDIRO. Once the switchover component successfully isolated the faulty component, the redundancy-recovery component checks whether the failure is due to a software or hardware component. In case a software instance failed, the redundancy-recovery component tries to find a computing node that offers enough resources to start a redundant

instance of the failed software. Note that this procedure is part of the standard FDIRO procedure.

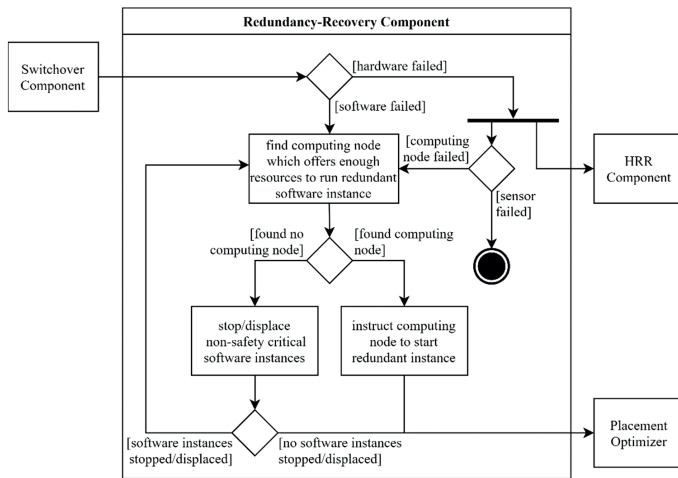


Fig. 5: The integration of the HRR component into FDIRO.

However, in case the failed component is a hardware part, the redundancy-recovery component triggers the execution of the procedure defined by the HRR component. Furthermore, in parallel, the redundancy recovery component checks whether the failed hardware is a computing node or a sensor. If it is a sensor, no further actions are required. In case, however, a computing node failed, all the software applications executed by this computing node failed as well. Consequently, the redundancy recovery procedure has to be executed in order to restore the software redundancy level.

#### 4.3 Use-Case

Let us assume a scenario where a monitor detects that the front-right radar sensor failed. Consequently, FDIRO isolates that component so that the data provided by this radar sensor is no longer used as input for any software application of the self-driving system. Once the front-right radar is isolated, FDIRO instructs the HRR component to start its repair procedure. A subset of the error categories for radar sensors is illustrated in Fig. 6. In this use-case, we assume that according to the error report provided by the monitor, the error category “value

constant” is the most fitting, i.e., the data points of the radar sensor are constant, e.g., in terms of the measured distance or relative velocity.

no.	error category	no.	S	O	D	RPN	fault	no.	effort [1,10]	repair approaches	parallel approaches
1	max value range exceeded	1	8	2	4	64	incorrect initialization of the sensor	1	4	reinitialization	-
2	values constant	2	8	6	2	60	dirt accumulation blocks the sensor	2	4	activate cleaning mechanism	No. 3
3	high frequency value oscillation							3	6	activate sensor heater	No. 2

Fig. 6: The error categories, faults, and repair approaches of a radar sensor.

As illustrated in Fig. 6, two faults, i.e., “incorrect initialization of the sensor” and “dirt accumulation blocks the sensor”, are defined for the considered error class, which are ordered according to their risk-priority number. Furthermore, for both faults, repair approaches are specified. In order to attempt to repair the faulty radar sensor, the HRR component first initiates a reinitialization of the sensor, as this repair approach is defined as a countermeasure for the fault having the highest risk-priority number. After the reinitialization of the front-right radar sensor terminates, a monitor determines whether the sensor is still faulty. In this use-case, we assume that the reinitialization of the sensor does not fix the fault, and the fault does not change during the repair procedure. Consequently, the HRR component executes the remaining repair approaches.

The next approach conducted by the HRR component in order to fix the fault is to activate the cleaning mechanism of the sensor. While executing this repair approach, the sensor heating is activated as well since those two approaches can be performed in parallel.

After the termination of both repair approaches, the monitor again checks whether the fault was fixed. Assuming this is the case, the HRR component logs the fault as well as the executed repair approaches and activates the sensor again.

## 5. Conclusion

In this paper, we introduced the hardware-redundancy recovery approach HRR, which is specifically designed for the use in autonomous vehicles. Furthermore, we illustrated that implementing a hardware-repair behavior can improve the system reliability of autonomous vehicles. Consequently, HRR is realized as an add-on to FDIRO, a fail-operational approach for autonomous vehicles, enabling the latter to now recover failures of both software and hardware components.

Concerning future work, we plan to implement the HRR approach in a case study for which we intend to demonstrate that the reliability of autonomous vehicles can be increased if their integrated fail-operational system implements a hardware-repair behavior.

## References

- [1] Caesar, H. , Bankiti, V., Lang, A., Vora, S. Liong, V. E., Xu, Q., Krishnan, A., Pan, Y., Baldan, G., and Beijbom, O.: nusenes: A Multimodal Dataset for Autonomous Driving. In Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020, pages 11618-11628.
- [2] Horeis, T. F., Kain, T., Müller, J.-S., Plinke, F., Heinrich, J., Wesche, M., and Decke, H.: A Reliability Engineering Based Approach to Model Complex and Dynamic Autonomous Systems. In Proceedings of the 3rd International Conference on Connected and Autonomous Driving (MetroCAD). 2020.
- [3] Kain, T., Tompits, H., Müller, J.-S., Mundhenk, P., Wesche, M., and Decke, H.: FDIRO: A General Approach for a Fail-Operational System Design. In Proceedings of the 30th European Safety and Reliability Conference (ESREL). 2020.
- [4] Koopman, P., and Wagner, M.: Autonomous Vehicle Safety: An Interdisciplinary Challenge. IEEE Intelligent Transportation Systems Magazine. 2017, 9(1):90–96.
- [5] Qin, J., and Li, Z.: Reliability Modeling for Multistate System with Preventive Maintenance under Customer Demand. Complexity in Economics and Business. 2020.
- [6] Raghavaiah, N., and Hariprasad, I.: Maintenance and Reliability Strategy of Mechanical Equipment in Industry. International Research Journal of Engineering and Technology (IRJET). 2019, 6(6):3430–3432.
- [7] SAE International. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles. In SAE Standard J3016, pages 1–16, 2018.
- [8] Selcuk, S.: Predictive Maintenance, its Implementation and Latest Trends. In Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture. 2017, 231(9):1670-1679.
- [9] Teng, S.-H. G., and Ho, S.-Y. M.: Failure Mode and Effects Analysis: An Integrated Approach for Product Design and Process Control. International Journal of Quality & Reliability Management. 1996, 13(5):8–26.

## **Ansatz zur methodischen Analyse und Absicherung des Funktionskonzepts voll automatisierter Kraftfahrzeuge**

### **Approach towards the methodical analysis of the safety of the functional concept of fully automated vehicles**

Dr.-Ing. **Matthias Rauschenbach**, M.Sc. **Simon Kupjetz**,  
Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF,  
Darmstadt;

M. Sc. **Christian Wolschke**, Dr. Ing. **T. Braun**,  
Fraunhofer-Institut für Experimentelles Software Engineering IESE,  
Kaiserslautern

#### **Kurzfassung**

Die Entwicklung hoch und voll automatisierter Fahrzeuge bringt nicht nur neue technologische Herausforderungen mit sich, sondern auch solche hinsichtlich der Herangehensweisen und Methoden im Produktentwicklungsprozess. Hierzu wird eine systematische Vorgehensweise benötigt, um erforderliche Spezifikationen des autonomen Fahrzeugs in Interaktion mit dessen Umgebung in hinreichender Weise definieren und verifizieren zu können. Entsprechende Fragestellungen werden im BMWi-Förderprojekt „Verifikation und Validierung autonomer Systeme“ betrachtet. Der Fokus dieses Beitrags richtet sich auf das Problem, durch voll automatisierte Fahrzeuge in allen Verkehrssituationen eigenständig hervorzubringende Verhaltens- und Funktionsweisen hinsichtlich möglicher Fehler analysieren sowie zu erreichender Sicherheit auswerten zu können. Als Erweiterung zu aktuell verfügbaren Ansätzen wird hier eine Modellierung von Fehlerszenarien und –reaktionen in probabilistischen Kausalmodellen durch Component-Fault-Trees (CFTs) vorgeschlagen, die durch Elemente und Schemen der Methode der probabilistischen FMEA (probFMEA) ergänzt werden. Dies erlaubt eine umfassende systematische Suche und formale Beschreibung der Kausalbeziehung zwischen Fehlerursachen und –folgen. Als weitere Besonderheit ermöglicht der Ansatz eine Analyse des übergeordneten Funktionskonzepts und der dadurch zu erreichenden Fähigkeiten des Systems, die zur Realisierung des Verhaltens des automatisierten Fahrzeugs benötigt werden. Dieser Ansatz erlaubt auch die analytische Betrachtung und Beurteilung sowohl von Fehlern im Sinne der funktionalen Sicherheit sowie der Sicherheit der beabsichtigten Funktion (SOTIF), als auch von Fähigkeitseinbußen mit der Folge von Verhaltensfehlern im Kontext definierter Fahrscenarien und Umfeldbedingungen.

## 1. Einführung

Die Entwicklung voll automatisierter Fahrzeuge wirft neue Herausforderungen bezüglich geeigneter Vorgehensweisen und Techniken zur Analyse der konzeptionellen und funktionalen Auslegung, sowie deren Implementierung auf. Unter anderem bedarf es geeigneter methodischer Ansätze zur analytischen Überprüfung und Bewertung der sicheren Ausführung eines angemessenen Verhaltens in allen Situationen im Straßenverkehr.

Für Kraftfahrzeuge wird für die Entwicklung elektrisch und elektronisch realisierter Produktfunktionen mit Sicherheitsrelevanz in der Norm für funktionale Sicherheit (ISO 26262) [1] unter anderem gefordert, Methoden, wie eine Gefährdungsanalyse und Risikobeurteilung (engl. Hazard Analysis and Risk Assessment, HARA) [2], Fehlerbaumanalyse (engl. Fault Tree Analysis, FTA) [3, 4] und eine Fehlermöglichkeits- und Einflussanalyse (FMEA) [5, 6, 7] durchzuführen. Hieraus müssen Verbesserungs- und Absicherungsbedarfe der Systemauslegung abgeleitet werden. Letztere dienen abschließend zur Verifikation und Validierung der Systemsicherheit hinsichtlich ausreichend geminderter Restrisiken. Während die HARA systematisch alle anzunehmenden Gefährdungen durch die jeweiligen Funktionen ermittelt, zielen FTA und FMEA auf die Betrachtung des implementierten Funktionsentwurfs und der Komponentengestaltung ab. Dabei ist es vorrangig von Interesse, in FTA und FMEA mögliche Fehler von Komponenten und deren Ursachen zu finden, die sicherheitskritische Effekte mit potenziell gefährlichen Konsequenzen für das Produktverhalten haben können und hierauf basierend geeignete Maßnahmen zu identifizieren.

Für automatisierte Fahrzeuge reichen die Betrachtungsweisen und die methodische Systematik der funktionalen Sicherheit nicht aus, da diese ein vollständig definierbares Funktionalverhalten des Systemverhaltens im Betriebskontext, sowie der Versagensmöglichkeiten aufgrund von Bauteilfehlern zugrundelegt. Daher legt der Standard ISO/PAS 21448 „Road vehicles - Safety of the intended functionality“ (SOTIF) [8] eine zur funktionalen Sicherheit komplementäre Systematik fest, mit der Fahrfunktionen niederer Automationsgrade hinsichtlich der Sicherheit der beabsichtigten Funktionsweise bewertet und verifiziert werden können. In dieser Beurteilung der Sicherheit sind situationsabhängige sowie prinzipbedingte Schwächen z.B. in der Umfeldbeobachtung oder Szenarieneinschätzung inbegriffen. Darüber hinaus wurde im BMWi-Projekt PEGASUS eine Systematik zur „Identifikation und Quantifizierung von Automationsrisiken für hochautomatisierte Fahrfunktionen“ [9] definiert, die die Betrachtung auch für höhere Automationsgrade ermöglicht.

Im aktuellen Entwurfsstand ISO/DIS 21448 wird das SOTIF-Konzept auf voll automatisiertes Fahren ausgeweitet [10]. Für hoch- und vollautomatisiertes Fahren (HAF, VAF) übersteigt die notwendigerweise stark situationsabhängige funktionale Flexibilität die Grenzen spezifisch beschränkter automatisierter Fahrfunktionen wesentlich, unter anderem auf Grund der Vielfalt und Komplexität von Verkehrssituationen und Randbedingungen. Das Fahrzeug muss in der Lage sein, das eigene (Funktions-)Verhalten kontinuierlich unter teils unvollständiger Beobachtbarkeit des Umfelds anhand von Abschätzungen und Prognosen im laufenden Betrieb vorausschauend selbst zu ermitteln, zu generieren und zu überwachen. Für eine analytische Betrachtung und sicherheitsgerichtete Verifikation der Auslegung eines solchen Systems fehlen nach Einschätzung der Verfasser aktuell geeignete Ansätze.

In dem vom Bundesministerium für Wirtschaft und Energie BMWi geförderten Projekt „Verifikation und Validierung autonomer Systeme“ (VVMethoden) werden derzeit methodologische Konzepte zur Verifikation und Validierung vollautomatisierter Fahrzeuge erarbeitet. Dieser Beitrag entstammt einem aktuellen Arbeitspunkt in VVMethoden zur methodischen Analyse und Verifikation der Systemauslegung gegenüber den Sicherheitsanforderungen. Im Folgenden wird ein Ansatz vorgeschlagen, der eine systematische Fehleranalyse gegenüber spezifizierten Komponenteneigenschaften, konzipierter Systemfunktionen und des zu erreichenden Fahrzeugverhaltens mit dem Ziel einer Sicherheitsbewertung ermöglicht.

## 2. Problem

Die Systematiken der Sicherheitsbewertung für funktionale Sicherheit nach ISO 26262 und für die Sicherheit der beabsichtigten Funktion (SOTIF) nach ISO 21448 können einen wesentlichen funktionalen Bestandteil hochautomatisierter Fahrzeuge nicht bzw. nur indirekt erfassen. Dies liegt daran, dass in der funktionalen Sicherheit vorrangig Fehlerwirkungen von Bauteilen und Baugruppen analysiert werden. Mit SOTIF werden systematische Schwächen der vorgesehenen Komponenten unter bestimmten Bedingungen zusätzlich betrachtet. Im Vorgängerprojekt PEGASUS wurde zuvor bereits eine Systematik zur Gefährdungs- und Fehleranalyse hinsichtlich Automationsrisiken von Fahrfunktionen höherer Automatisierungsgrade entwickelt [9]. Diese bezieht auch die übergeordnete funktionale Architektursicht der Komponenten in die analytische Verifikation der Fahrfunktion mit ein.

Für hoch- und vollautomatisierte Fahrzeuge sind umfassende Fähigkeiten im Systemkonzept zu definieren, durch welche es dem Fahrzeug möglich wird, der Situation angepasste Verhaltensweisen selbständig zu generieren, diese als hinreichend sicher einzustufen und daraufhin in entsprechender Weise umzusetzen. In wissenschaftlichen Arbeiten wird die systematische

Entwicklung anhand von Fähigkeitenmodellen für automatisierte Fahrzeuge vorgeschlagen [11, 12]. Diese Fähigkeiten, auf Basis derer das jeweils sichere Verhalten des Fahrzeugs in betreffenden Betriebsszenarien generiert wird, werden durch die im Fahrzeug realisierten Funktionskonzepte erzeugt, welche wiederum auf der Implementierung der strukturellen Bestandteile beruhen. Während bisherige Ansätze mögliche Fehler methodisch mit Fokus auf Komponentendefekten sowie in Funktions- und Spezifikationsfehlern, sowie technologischen Schwächen ermitteln, werden solche Fähigkeiten als Träger der jeweils situationsabhängigen Verhaltensweise des automatisierten Fahrzeugs nicht behandelt. Das zu erreichende Verhalten, mögliche Abweichungen davon, sowie deren Ursachen werden nicht betrachtet. Ein analytischer Ansatz hierzu existiert nach Kenntnis der Verfasser bislang nicht.

### 3. Stand der Wissenschaft und Technik

In [11, 12] wird für automatisierte Fahrzeuge die Beschreibung der für die Fahraufgabe erforderlichen Fähigkeiten, sowie deren Abhängigkeiten voneinander in Form von azyklischen gerichteten Graphen zusätzlich zur funktionalen Systemarchitektur vorgeschlagen. Nach [12] definieren sich Fähigkeiten eines Systems als dessen Aktivitäten, die umgesetzt werden müssen, um die für das System definierten Ziele zu erfüllen. Die hierarchisch aufgebauten Fähigkeitengraphen sind unabhängig von dem spezifischen Aufbau des Systems. Die Modellierung solcher Fähigkeitennetzwerke während der Konzeptphase der Systementwicklung bringt Informationen darüber hervor, wie das Fahrzeug in die Lage versetzt wird, die Fahraufgabe sicher umsetzen zu können und wie die Abhängigkeiten der Fähigkeiten untereinander interagieren [11]. Dabei kann das externe Verhalten des Fahrzeugs in Form eines Fahrmanövers basierend auf dem internen Verhalten anhand des Fähigkeitengraphs beschrieben werden. Auf diesem Zusammenhang basierend wurde durch [13] eine systematisierte Gefährdungsidentifikation für automatisierte Fahrfunktionen auf der Grundlage eines Fähigkeitenmodells umgesetzt.

Das im PEGASUS-Projekt entwickelte Methodenschema zur Analyse von Automationsrisiken [9] baut auf einer aus der ISO 26262 abgeleiteten und modifizierten Gefährdungs- und Risiko-bewertung von hochautomatisierten Fahrfunktionen auf. Diese wird für automatisierte Fahrfunktionen ausgehend von einer gegebenen Struktur der für die Funktion spezifisch relevanten Verkehrsszenarien und Basismanöver des Fahrzeugs durchgeführt. Für identifizierte Gefährdungsmöglichkeiten wird jeweils eine Wirkkettenanalyse auf Grundlage einer modifizierten FTA durchgeführt. In dieser erfolgt eine typische Identifikation möglicher Fehlerursachen entlang funktionaler Wirkketten. Das oberste Element der Analyse (engl. Top-Level-Event, TLE) ist die Verletzung eines Sicherheitsziels bzw. einer Sicherheitsanforderung. Zusätzlich werden



Randbedingungen mittels einer Umgebungsbedingungsanalyse identifiziert, die zum Hervorrufen der kritischen Auswirkung vorliegen müssen. Während der adaptierten HARA und FTA werden sogenannte Leitworte (analog zu [8]) angewendet, um mögliche Fehler und Abweichungen zu ermitteln. Diese dienen dem systematischen und umfassenden Ermitteln möglicher Abweichungen. In einem abschließenden Schritt können mit einer entsprechenden Datengrundlage Wahrscheinlichkeiten für kritische Szenarien ermittelt werden, indem die Gesamtheit der ermittelten Kombinationen unter Berücksichtigung der Wahrscheinlichkeit der jeweils zugrundeliegenden Umgebungs- und Randbedingungen ausgewertet werden.

In der klassischen Methode der FTA [3, 4, 14] wird eine Fehlermöglichkeit des Gesamtsystems als ein TLE fokussiert und von diesem ausgehend in das System hineinblickend (top-down) nach möglichen Ursachen hierfür gesucht. Die dabei gesammelten möglichen Ursachen werden als grafischer Baum formalisiert abgebildet, der logische Kombinationen für alternative Ursachen (logisch ODER) oder Fehlerkombinationen (logisch UND) enthält. Auf der Grundlage dieser logischen Strukturierung ist ein Fehlerbaum quantitativ auswertbar, d.h. die Wahrscheinlichkeit eines TLE ergibt sich aus der Gesamtheit der alternativ möglichen Einzelfehler und Fehlerkombinationen.

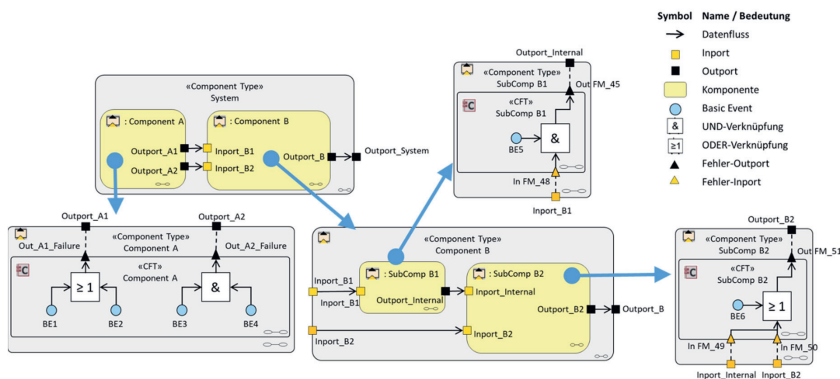


Bild 1: Beispiel eines hierarchischen Systems mit drei Komponentenfehlerbäumen

Die Analyse mit Komponentenfehlerbäumen (engl. Component Fault Tree, CFT) ist eine Erweiterung der klassischen Fehlerbaumanalyse [15]. Ziel ist es, das monolithische Vorgehen der Fehlerbaumanalyse aufzubrechen und eine modulare Fehlermodellierung zu ermöglichen. Die Struktur des CFTs verwendet hierbei die Systemarchitektur und deren Komponenten als Rankhilfe und erleichtert damit die Nachverfolgbarkeit. CFTs beziehen sich auf jeweils eine

Komponente des Systems. Bild 1 zeigt ein System, das zwei Komponenten A und B besitzt. Die Darstellung beinhaltet den Datenfluss, die Schnittstellen zwischen den Komponenten mittels der eingezeichneten Outports und Inports, sowie deren Verbindungsstruktur. Für einzelne Komponenten können wiederum hierarchisch untergeordnete CFTs dekomponiert werden. Die Outport-Fehlermodi dienen dabei innerhalb einer Komponente als TLE. In dem Beispiel beinhaltet die Komponente B die Subkomponenten „B1“ und „B2“. Im ersten Schritt wird für jeden Outport bestimmt, welche Outport-Fehlermodi möglich sind (bspw. „OutFM\_45“ für „Outport\_Internal“ im CFT für „SubComp B1“). Anschließend werden mögliche Fehlerursachen, die den Outport-Fehlermodus verursachen, ermittelt. Dies können Fehler sein, die in der Komponente selbst ursächlich entstehen. So kann bspw. „BE5“ im CFT für „SubComp B1“ einen internen Hardware-Fehler darstellen. Auch können Fehlermodi über die Inports, wie bspw. „FM\_48“ im CFT für „SubComp\_B1“) eingeleitet werden und deren Effekt durch die Komponente propagieren. Durch die Portverbindungen kann eine Fehlerpropagation durch das System über einzelne CFTs automatisch nachvollzogen werden. Gleichzeitig stellt die Zuordnung der Fehlermodi zu In- und Outports die Verbindung zur Architektur und den definierten Komponentenschnittstellen her und ermöglicht die Nachverfolgung. CFTs ermöglichen es, die Komplexität des Systemfehlerbaums auf einzelne Fehlerbäume herunterzubrechen und durch die explizite Verknüpfung der Komponenten der Architektur eine Nachvollziehbarkeit der CFTs sowie der Propagierung der Fehler zu erreichen.

Die FMEA [5, 6] ist eine weit verbreitete und bewährte Methode zur Analyse von Produktauslegungen vor der Inverkehrbringung. Die in dem Produktentwurf spezifizierten Bauteile werden hinsichtlich möglicher Fehler und deren Auswirkungen auf das Verhalten des Produkts in der Nutzung systematisch ermittelt („bottom-up“). Zusätzlich werden die Wahrscheinlichkeit des Auftretens der Fehlerursache, sowie die Bedeutung der möglichen Fehlerfolgen auf einer qualitativen Werteskala von 1 bis 10 eingestuft. In gleicher Weise wird auch die Wahrscheinlichkeit einer möglichen Entdeckung bis dato gegebenenfalls unterschätzter Fehler insbesondere durch Versuche eingeschätzt, sowie die Möglichkeit der Fehlerdetektion im Betrieb, wenn dadurch kritische Folgen wirksam abgewendet werden können. Das Produkt der Bewertungsparameter, die eine sogenannte Risikoprioritätszahl indiziert, ob das Risiko gering genug ist oder dieses durch Verbesserungen bzw. Überprüfung durch Tests reduziert werden muss.

Da die FMEA ausschließlich qualitative Beurteilungen für einzelne Fehlermöglichkeiten erlaubt, wurde ein erweiternder Formalismus zur quantitativen Auswertung, die probabilistische FMEA (probFMEA) entwickelt [16, 17]. Dieser definiert analog zur FTA logische Operationen

für die Zusammenhänge von Fehlerursachen und Folgen, sodass eine probabilistische Auswertung möglich wird. So können mehrere Fehlerursachen zur gleichen (logisch ODER) sowie mehrere Ursachen in Kombination (logisch UND) zu einer bestimmten Folge führen. Auch kann eine Ursache zu mehreren alternativen Folgen führen, mit einer jeweils zu spezifizierenden bedingten Wahrscheinlichkeit. Ein nach einer visualisierten Form der FMEA basierend auf Fehlernetzen [7] aufgebautes Kausalmodell mit entsprechender Erweiterung der probFMEA kann schließlich als ein stochastisches Netzwerk mittels Bayesscher Netze berechnet werden. Ein wesentlicher Unterschied zur FTA ist hierbei, dass ein solches probFMEA-Fehlernetz nicht auf einen spezifischen übergeordneten Fehlereffekt eines TLEs beschränkt ist, sondern alle ermittelten TLE in Bezug zu den jeweiligen Ursachen setzt. So lassen sich auch die Wechselwirkungen durch Fehlermonitoring und –reaktionen von Sicherheitsmaßnahmen abbilden, in dem sowohl die dadurch beeinflusste Wahrscheinlichkeit der gefährlichen Folge modelliert werden kann, als auch die durch dessen Eingreifen hervorgerufene Folge, wie beispielsweise eine sichere Abschaltung oder ein leistungsgeminderter Notlauf.

#### 4. Ansatz

Dieser Beitrag beschreibt einen methodischen Ansatz zur Analyse möglicher kritischer Fehler vollautomatisierten Fahrens (VAF). Mögliche Fehlerphänomene werden analog zu der Wirkkettenanalyse in der PEGASUS-Systematik [9] mit der Methodik der Component Fault Trees (CFT) und Kernelementen des Formalismus der probabilistischen FMEA (probFMEA) beschrieben und ausgewertet. Dazu werden das Nichterreichen des sicheren Verhaltens aufgrund von Abweichungen definierter Funktionsweisen und Komponenteneigenschaften, sowie zusätzlich der zu erzeugenden Fähigkeiten systematisch untersucht. Ausgehend von in einer HARA festgestellten Gefährdungsszenarien werden in den Systembeschreibungen der Fähigkeiten, Funktionsstrukturen und Komponentengestaltung mögliche Ursachen ermittelt, die zu diesen führen können.

Der vorgestellte Ansatz bezieht im Unterschied zu bisherigen Ansätzen definierte Fähigkeiten und übergeordnete Funktionsweisen des Fahrzeugs mit ein, da diese unmittelbar mit dem Verhalten des Fahrzeugs in Verbindung stehen. Dies ermöglicht eine Beurteilung kontextspezifischer Konsequenzen aufgrund der durch Fehler hervorgerufenen Verhaltensabweichungen. Zugleich verhilft die Berücksichtigung der unter Fehlerwirkung entstehenden Abweichungen der Fähigkeiten dazu, dass daraus hervorgerufene Fahrzeugverhalten im Kontext der jeweils betreffenden Fahrsituation zu beurteilen. Dies ist für die Sicherheitsverifikation vollautomatisierter Fahrzeuge von zentraler Bedeutung, da eine situationsunabhängige Bewertung

aufgrund des hohen Automationsgrads analytisch nicht zu erfassen und eine subsummierte Bewertung der Restrisiken nicht möglich wäre.

#### 4.1. Annahmen und Vorbedingungen

Der hier dargestellte methodische Ansatz setzt als a priori gegebene Informationsquelle eine entsprechende HARA einschließlich der relevanten Fahrmanöver und Szenarien voraus. Zusätzlich ist der Bezug auf eine gegebene Systemdefinition, Fähigkeitengraph, sowie Funktions- und Systemstruktur erforderlich, um eine Beurteilung der Fehlereffekte und Wirkketten erreichen zu können. Zusätzlich muss eine Spezifikation der je nach Situation umzusetzenden Verhaltensweisen, sowie des zu erreichenden sicheren Sollverhaltens verfügbar sein. Ferner wird für diese Erläuterungen von einer auf Szenarien und Manöver bezogenen HARA wie in der Automationsrisikenmethode aus PEGASUS [9] ausgegangen, die sich prinzipiell analog zu gebräuchlichen Ansätzen für funktionale Sicherheit und SOTIF verhält. Noch mehr, als es bereits im PEGASUS-Kontext für HAF gilt, besteht für VAF jedoch der Unterschied, dass keine Einflussnahme oder Kontrollierbarkeit durch einen menschlichen Fahrer zur Risikominderung beitragen kann. Stattdessen müssen sämtliche Vorkehrungen und Mechanismen zur Risikominderung im automatisierten System konzeptionell und funktional in der Systemdefinition implementiert werden. Zusätzlich zu potenziell gefährlichen Komponentenfehlern und der Absicherung von Schwächen müssen auch Beeinträchtigungen von Fähigkeiten, sowie daraus resultierendes Fehlverhalten abgesichert werden.

Der methodische Ansatz zur Systemfehleranalyse bezieht neben der gebräuchlichen Betrachtung struktureller und funktionaler Elemente des Fahrzeugsystems auch ein Modell der zu realisierenden Fähigkeiten mit ein, aus welchem das für die Teilnahme am Straßenverkehr erforderliche Verhalten hervorgeht [11]. Für den hier dargestellten Beitrag werden fiktive generische Elemente eines hypothetischen Fähigkeitenmodells eines vollautomatisierten Fahrzeugs beispielhalber zugrunde gelegt<sup>1</sup>. Die in diesem Beitrag gezeigten Inhalte und Daten der Beispieldarstellungen wurden willkürlich zum Zweck der Erläuterung gewählt<sup>2</sup>.

#### 4.2. Aufbau

Die Methodik baut analog zu der Wirkkettenanalyse der Automationsrisikenmethode in [9] auf gebräuchlichen Formalismen der FTA-Methodik auf, wobei diese nun auch auf die Fähigkeiten-tenarchitektur des Systems angewendet wird. Als Kernansatz wird die Methodologie der CFTs

<sup>1</sup> Die Elemente sind exemplarischer Art in Anlehnung an Inhalte einer ausgestalteten Fähigkeitenarchitektur für VAF im Konsortium des Projekts VVM, basierend auf in [10] beschriebenen Ansätzen.

<sup>2</sup> Beispieldarstellungen stellen keine Beurteilung realer Fahrzeuge dar und sind nicht auf solche übertragbar.

zur Modellierung von Kausalitäten und Wirkketten eingesetzt. Diese wurde um einzelne Elemente zur Erfassung von SOTIF-Fehlern und Umgebungsbedingungen adaptiert, sowie um Elemente und Schemen der probabilistischen FMEA (probFMEA) ergänzt. Letzteres betrifft insbesondere die quantitative Berücksichtigung des Diagnosedeckungsgrads von Sicherheitsmaßnahmen, also des Diagnoseschlupfs, sowie ein mögliches falsch-positives Auslösen mit der Folge eines unnötig gestörten Systembetriebs. Die anzuwendende Methodik zielt darauf ab, die Ergebnisse nachvollziehbar, vollständig und analysierbar zu machen.

Da, wie in [12] dargestellt wird, Fähigkeiten auch funktionale und strukturelle Redundanzen abbilden, bietet dies eine Basis, um auch Sicherheitsmaßnahmen auf dieser Ebene analysieren zu können. Zu diesem Zweck wird hier der methodische Ansatz einer Fehleranalyse ausgehend von der Verhaltensebene, die durch eine Fähigkeitensicht repräsentiert wird, vorgeschlagen. Dadurch können mögliche Ursachen von Verletzung von Sicherheitszielen in Verkehrssituationen analysiert und die Wirkung von Sicherheitsmaßnahmen beurteilt werden.

#### **4.3. Top-Down Ursachenanalyse von SOTIF-Aspekten in Verkehrssituationen mit CFTs**

Als Beispiel für die Erläuterung unserer Methodik dient eine Straßenkreuzung innerorts für die Analyse als Verkehrssituation, bei der das voll automatisierte Fahrzeug rechts abbiegen und ein Fußgänger einen dort vorhandenen Fußgängerüberweg passieren möchte. Es wird vorausgesetzt, dass bereits ein Sicherheitsziel festgelegt wurde, aus dem sich ein sicheres Verhalten des Fahrzeugs ableiten lässt. In dieser Situation bedeutet dies, dass das Fahrzeug in dieser Situation vor dem Fußgängerüberweg anhalten muss. Die CFT-Analyse soll die Frage beantworten, ob die vorgesehenen Fähigkeiten und umgesetzten Maßnahmen für die Verkehrssituation ausreichen und die Wahrscheinlichkeit einer Sicherheitszielverletzung hinreichend gering ist. Beim Entwurf der CFTs wird für jede Sicherheitszielverletzung ein an der Architektur ausgerichtetes Fehlermodell erstellt. Im Gegensatz zu einem klassischen CFT, werden als Fehlerursachen nicht nur Aspekte der funktionalen Sicherheit, sondern auch die Sicherheit der beabsichtigten Funktionsweise im Sinne von SOTIF, sowie Randbedingungen der Umwelt berücksichtigt.

Die Fähigkeitenarchitektur in Bild 2 zeigt eine stark vereinfachte Beispieldarstellung des Datenflusses. Zur CFT-Analyse wird die Sicherheitszielverletzung, die sich beim System-Output zeigt, als TLE entlang der Sequenz der Abhängigkeiten der Fähigkeiten voneinander analysiert (s. Bild 3). Mit dem Top-Down-Ansatz werden diesem mögliche Fehlerursachen zugeordnet. Für jede Komponente innerhalb der Sequenz der Fähigkeiten, die durch einen Output potentiell zur Sicherheitszielverletzung beiträgt, wird analysiert, welche Funktionen sie ausübt und

ob bzw. welche Funktionsfehler an deren Schnittstelle einen Beitrag zur Verletzung des Sicherheitsziels liefern. Da die Komponenten hierarchisch aufgebaut sind, wird dieses Vorgehen rekursiv innerhalb der Komponenten jeweils wiederholt. Bei der Modellierung des internen Fehlermodells einer Komponente gelangt man bei der Analyse so sukzessive zu den Inports, die zu dem Fehler führen oder mit zu diesem beitragen können. Da die identifizierten Fehler an den Inports gleichzeitig die Fehler der Outports der vorgelagerten Komponenten sind, kann die Analyse systematisch entlang der Wirkkette fortgesetzt und die Fehlerpropagationen innerhalb des Systems modelliert und analysiert werden.




Bild 2: Vereinfachte Fähigkeitsarchitektursicht<sup>1</sup>

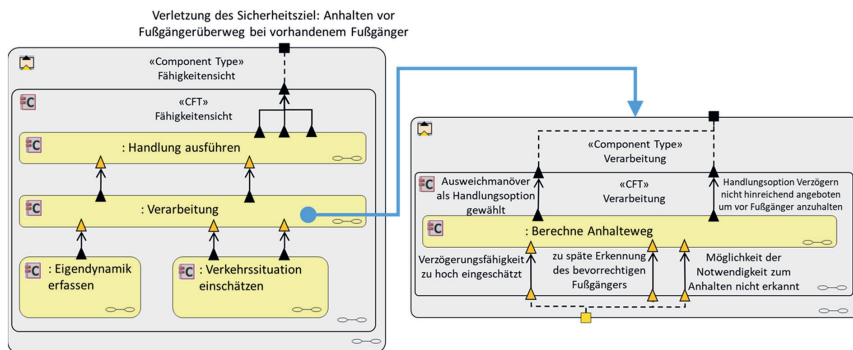


Bild 3, links: CFT mit Fehlerpropagation über Komponenten hinweg (Fehlernamen wurden für die Übersichtlichkeit entfernt); rechts: CFT mit situationsbasierten Fehlerursachen für Komponente "Verarbeitung"

Bild 3 zeigt, wie die Verletzung des Sicherheitsziels in der Komponente „Verarbeitung“ neben Fehlern aus der Subkomponente „Berechne Anhalteweg“ auch durch Inport-Fehler verursacht wird. Die identifizierten Fehler können dabei von der Verkehrssituation unabhängige Fehler oder situationsabhängige Fehler sein. Die Fehleranalyse im SOTIF-Kontext ist dabei so angepasst, dass neben sicherheitskritischen Komponentenfehlern bezüglich funktionaler Sicherheit

(bezeichnet mit dem Präfix FuSi) auch bewusst Schwächen der Wahrnehmung, wie bspw. insbesondere Sensorikschwächen, als auch der gegebenenfalls zugrundeliegenden Berechnungsmodelle explizit erfasst und analysiert werden können.

Der Fehler „*Verzögerungsfähigkeit zu hoch eingeschätzt*“ ist situationsunabhängig, so dass der CFT für die Fähigkeit „*Eigendynamik erfassen*“ unverändert in anderen CFTs genutzt werden kann. Er umfasst neben der Möglichkeit interner FuSi-Fehler für Verzögerungen mögliche Fehler bei der „*Einschätzung der Verzögerungsfähigkeit*“, die auf der „*Detektion von Feuchtigkeit*“ als Indikator für reduzierte Reibungskräfte beruhen (s. Abbildung 4). Ein CFT zu einer Detektion wendet dieses Muster an. Es berücksichtigt generisch die Annahme, dass bestimmte SOTIF-Aspekte durch die Modellierung unzureichend adressiert sind. Dies wird durch das Basic Event innerhalb des rechten CFTs in Bild 4 repräsentiert. Das Muster enthält konkret, wie die Detektion stattfindet und welche Plausibilisierung vorgesehen ist. Im Beispiel in Bild 4 wird die Detektion durch drei verschiedene Mechanismen realisiert. Das CFT-Beispiel zur Detektion von Nebel (Abbildung 5) zeigt, dass für die Problemklasse bekannte Schwächen (Weakness) und mögliche auslösende Bedingungen (Triggering Condition) erfasst werden können. Die Auslöser und Schwächen werden hierbei getrennt modelliert, so dass in der weiteren Analyse ontologische Beziehungen zwischen Triggerbedingungen und somit Abhängigkeiten erkannt und ggf. quantifiziert werden können.

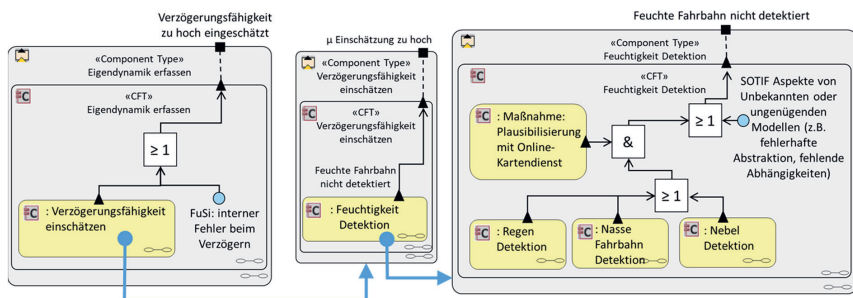


Bild 4: Herleitung eines Detektionsmechanismus

Im Weiteren werden die getriggerten Schwächen (Triggered Weakness) durch die CFTs propagiert und beschrieben, an welchen Stellen Sicherheitsmaßnahmen eingreifen bzw. durch welche weiteren Fehler dies nicht gelingt (s. Abbildung 5). Durch eine zusätzliche Erweiterung des Formalismus der CFTs in Form von Kausalitäten und bedingten Wahrscheinlichkeiten ist es möglich, auslösende Bedingungen miteinander in Beziehung zu setzen. Dies erlaubt es

unter anderem, die kausalen Abhängigkeiten von Phänomenen in Umwelt und Umgebung zu berücksichtigen. Beispielsweise implizieren Regen oder starker Nebel eine nasse Fahrbahn, sowie zugleich eine begrenzte Sichtweite und Erkennungsgenauigkeit optischer Systeme. Für die quantitative Auswertung solcher Fehlerbeziehungen mit stochastischen Abhängigkeiten lassen sich Bayessche Netze nutzen [16]. Wie in [18] gezeigt wird, ist eine Abbildung der Elemente eines Fehlerbaums auf die Semantik Bayesscher Netze automatisiert möglich.

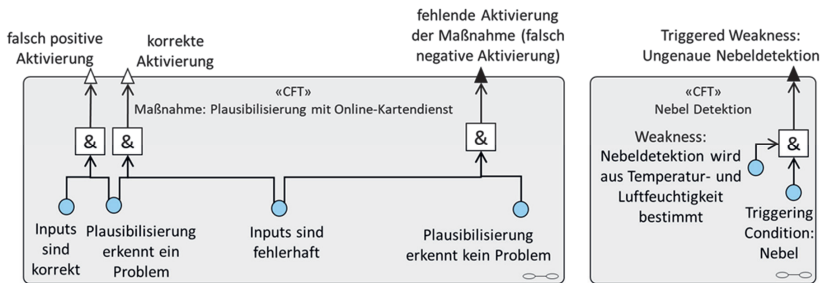


Abbildung 5: Muster der Einflüsse von Sicherheitsmaßnahmen (links) und Detektion (rechts)

In dem Beispiel wird ebenfalls dargestellt, wie eine weitere Propagation einer durch ein Triggering Event ausgelösten Schwäche nur bei einem gleichzeitigen Fehler der Sicherheitsmaßnahme möglich. Das in dem CFT umgesetzte probFMEA-Muster [16, 19] von Sicherheitsmaßnahmen (Abbildung 5, links) geht dabei von drei Grundkategorien aus (Bild 6, links): (a) einem Fehlermodus, in dem dieser korrekt erkennt, dass eine Wahrnehmungsschwäche vorliegt, sodass eine geeignete Reaktion zur Vermeidung gefährlicher Folgen getroffen werden kann, (b) einen Fehlermodus mit falsch positiver Aktivierung einer Sicherheitsmaßnahme, die zu einer unangebrachten Fehlerreaktion des Systems führt und (c) einem Fehlermodus mit falsch negativer Aktivierung, einem Versagen der Sicherheitsmaßnahme infolge eines begrenzten Diagnosedeckungsgrads oder wegen eines zuvor vorliegenden latenten Fehlers, sodass die sicherheitskritische Folge nicht abgewendet werden kann.

Situationsspezifische Analysen (s. Bild 6, rechts) untersuchen, in welchen Fällen die Schwächen der Fähigkeiten für die Situation problematisch sein könnten. Um für die Situation relevante Fußgänger hinreichend schnell erkennen zu können, sind nicht nur generell Personen zu erkennen, sondern auch korrekt einzuschätzen, ob diese den Fußgängerüberweg benutzen möchten oder nicht. Dabei muss das Fahrzeug beispielsweise auf unvermittelt erscheinende Fußgänger sicher reagieren können, die hinter einer Verdeckung hervortreten.



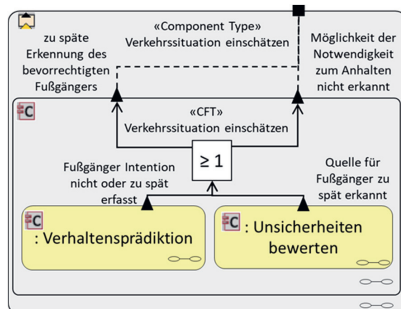
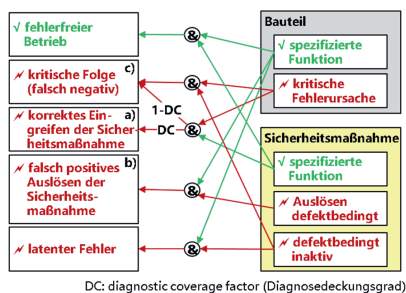


Bild 6, links: probFMEA-Muster der Inferenz von Sicherheitsmechanismen  
rechts: CFT zur situationsbedingten Analyse<sup>1</sup>

#### 4.4. Bottom-up Ermittlung zusätzlicher Fehlereffekte mittels FMEA-Verfahren

Die Top-Down-Analyse der CFT erfolgt jeweils mit dem Fokus auf ein notwendigerweise a priori bekanntes TLE, welches unter anderem aus den Ergebnissen einer HARA abgeleitet wird. Für eine umfassende Systemverifikation ist es zudem von Bedeutung, ob zusätzliche unberücksichtigte Ursachen sowie weitere kritische Folgen auf der Verhaltensebene aus Fehlern in den verschiedenen Ebenen innerhalb des Fahrzeugs hervorgerufen werden können. Durch das bottom-up Analyseverfahren der FMEA können mögliche Fehlermodi von Unterbestandteilen und deren Auswirkung auf das Fahrzeugverhalten ermittelt werden.

Die für die probFMEA definierte algebraischen Grundlage erlaubt es, die auf diesem Wege ermittelten Zusammenhänge in den Formalismus der CFT zu integrieren. Dazu werden mögliche Fehlermodi in allen Systembestandteilen, die funktional zu den für das betrachtete Szenario erforderlichen Fähigkeiten beitragen, ermittelt. Deren Auswirkungen auf das Systemverhalten können von diesen Komponentenfehlern ausgehend (bottom-up) untersucht werden. Gegebenenfalls zuvor unberücksichtigte Basic Events werden in bereits vorhandene CFTs nachgepflegt bzw. neue, zuvor nicht identifizierte kritische TLEs für nachfolgende weitere CFT-Analysen definiert. Durch die Ergänzung kann die Vollständigkeit der Analyse im Hinblick auf eine darauf abstellende Sicherheitsargumentation und Verifikation erhöht werden.

Bei der Durchführung werden Funktionsweisen und Eigenschaften der jeweils zugehörigen Elemente in Bezug auf die in Tabelle 2 dargestellten Hierarchieebenen hinterfragt. Für diese werden Annahmen getroffen, welche Möglichkeiten von Abweichungen auftreten könnten. Hierzu empfehlen sich neben der Experteneinschätzung auch Hilfsmittel wie Leitwortlisten mit hypothetisch möglichen Abweichungen analog zu der zuvor erläuterten Vorgehensweise bei

CFTs sowie in [9]. Um ebenfalls die Robustheit gegenüber Schwächen im Sinne der SOTIF und Verhaltensabweichungen zu ermitteln, kommen dabei auch Abhängigkeiten der Fehlerwirkungen von äußeren Einflüssen aus Witterung, Straßentopologie und –zustand, sowie besonderer Ereignisse in Betracht. Diese werden in gegebenenfalls bereits bestehende CFTs aufgenommen, soweit diese zu dem betrachteten TLE führen. Andernfalls ist zu prüfen, ob diese eine Sicherheitszielverletzung oder wesentliche Verhaltensabweichung hervorrufen, die noch nicht erkannt bzw. näher untersucht wurde. Diese kann nachfolgend wiederum als TLE neu aufzubauender CFTs festgelegt werden. Zu den gleichen Zwecken ist die Fehlerwirkung für Outports von CFT-Elementen, welche zu gegebenem Zeitpunkt mit keinem CFT verbunden sind, zu überprüfen. Ergänzende Blickwinkel zur Identifikation weiterer Fehlermöglichkeiten sind mögliche Fehlermodi durch von außen oder zwischen Systembestandteilen wirkenden Betriebs- und Umgebungsbeanspruchungen. Insbesondere mögliche Fehler gemeinsamer Ursache können aus dieser Perspektive gezielt gesucht werden.

Tabelle 2: Kombinierte Vorgehensweise aus Analyseschritten der CFT und probFMEA

Sicht	Ebene	Analyseinhalt	CFT (↓ Identifikation)		probFMEA (↑ Folgerung)
			Top-Level-Event, TLE		mögliche Verhaltensfehler
Verhaltenssicht	Fahrzeugverhalten (im Szenario)	Verhaltensabweichungen / -fehler	↓	Welche Fähigkeitsdefizite und -abweichungen, können zu bestimmter Verhaltensabweichung führen?	↑ Zu welchen Verhaltensabweichungen führen mögliche Fähigkeitsdefizite?
Fähigkeits-sicht	Fähigkeiten	Fähigkeitsdefizite		Welche funktionalen Schwächen und -abweichungen können zu bestimmtem Fähigkeitsdefizit führen?	↑ Zu welchen Fähigkeitsdefiziten führen funktionale Schwächen und -abweichungen?
technische Sicht	Systemstruktur	Schwächen und Abweichungen von beabsichtigter Funktion	↓	Durch welche Fehler in Bauteilen und Software kann betreffende Funktionsabweichung entstehen?	↑ Zu welchen Funktionsabweichungen führen mögliche Bauteil- und Softwarefehler?
	Einzelbestandteile	Fehler und Versagen von Einzel-elementen, Bauteilen, Software			

4.5. Minimal-Cut-Set-Analyse und quantitative Auswertung

Mit der für die Auswertung der FTA gebräuchlichen sogenannten Minimal-Cut-Set-Analyse ist es möglich, zu bestimmen, welche minimale Kombination von Basic Events getriggert werden muss, durch die es zu einer Sicherheitszielverletzung kommt. Ferner kann durch Berücksichtigung der Wahrscheinlichkeiten der Basic Events und der UND- bzw. ODER-Verknüpfungen eine Wahrscheinlichkeit für die Sicherheitszielverletzung angegeben werden.

Ein Beispiel für ein Minimal Cut Set für Verletzung des Sicherheitsziels „Anhalten vor Fußgängerüberweg bei vorhandenem Fußgänger“ ist folgende Menge: {Triggering Condition: „Nebel

(1)“, *Weakness: „Nebeldetektion wird aus Temperatur- und Luftfeuchtigkeit bestimmt (1)“, „Inputs sind fehlerhaft (2)“, „Plausibilisierung erkennt kein Problem (2)“*. Die Basic Events mit dem Index (1) sind im CFT *„Nebeldetektion lokalisiert“* und die Basic Events mit dem Index (2) im CFT *„Maßnahme: Plausibilisierung mit Online-Kartendienst“* enthalten.

Eine nachgelagerte quantitative Bewertung der Fehlerwahrscheinlichkeiten weitet sich in dem hier dargestellten Ansatz über die typische Problemstellung der Verfügbarkeit von Auftretenswahrscheinlichkeiten zufälliger Bauteilfehler hinaus aus. Hierfür ist es zusätzlich nötig, auch Wahrscheinlichkeitswerte für das Auslösen von Schwächen unter situativ auftretenden äußeren Bedingungen, sowie für Verhaltensabweichungen anzugeben. Die Ermittlung quantitativer Werte lässt sich in einer ersten Iteration vorbehaltlich abschätzen, um den Produktentwicklungsprozess zielgerichteter umzusetzen. Für eine risikobasierte Argumentation eines übergeordneten Sicherheitsnachweises, können diese z.B. durch entsprechende fähigkeits- und verhaltensqualifizierende Simulationen, Integrationstests und Erprobungen ermittelt werden.

Das hier vorgestellte Konzept ermöglicht es prinzipiell, Wahrscheinlichkeitswerte für Komponentenfehler, funktionale Schwächen und Verhaltensfehler in einer Gesamtauswertung zu konsolidieren. Die quantitative Auswertung als komplexes Netzwerk aller ermittelten CFTs verhält sich analog zur Lösung der probFMEA, die als Bayessches Netz oder auf Basis mehrwertiger Zustandsdiagramme ausgewertet werden kann [16, 19].

## 5. Zusammenfassung

Durch die Kombination von CFT und probFMEA lässt sich ein methodisches Vorgehen umsetzen, das eine gezielte, auf definierte Szenarien bezogene Untersuchung und Bewertung des Risikos gefährlicher Verhaltensweisen des Fahrzeugs ermöglicht. Dies gelingt durch den Bezug auf Systemmodelle, die Komponenten-, Funktions- und Fähigkeitenstrukturen des Fahrzeugs enthalten. Die Analysemethode beruht auf einer Kombination aus CFTs und probFMEA, die auf diese Systemmodelle bezogen angewandt wird. Mit diesen werden Effekte möglicher Fehler in den verschiedenen Strukturmodellen hinsichtlich ihrer Wirkung auf das Fahrzeugverhalten in unterschiedlichen Verkehrssituationen betrachtet. So können sowohl FuSi, als auch SOTIF und Verhaltensfehler voll automatisierter Fahrzeuge betrachtet werden. Randbedingungen, wie besondere Ereignisse und Umfeldbedingungen können dabei ebenfalls einbezogen werden. Als weiterer Vorteil können anhand einer Unterscheidung zwischen situationsabhängigen und situationsunabhängigen Bestandteilen der Analyse, letztgenannte auf weitere

Kontexte zur Aufwandsreduktion übertragen werden. Durch die Formalismen der Analyse- methode können die darin abgebildeten Kausalbeziehungen auch quantitativ im Rahmen verfü- garer Techniken und Werkzeuge ausgewertet werden.

Im Rahmen des Projekts „Verifikations- und Validierungsmethoden - VVM“ werden die Autoren näher untersuchen und beurteilen, in welchem Umfang dieses methodische Konzept zu einer umfassenden Systemverifikation beitragen kann und wie sich dies in eine vollständige Sicher- heitsargumentation einbinden lässt. Zudem soll untersucht werden, wie die verfügbare Enter- prise Architect™ Erweiterung zur Modellierung von Safety-Artefakten (CFTs, GSN, HARA) Sa- feTBox<sup>3</sup> zur Abbildung und Auswertung von Abhängigkeiten der Fehlerwirkungen von äußeren Einflüssen aus Witterung, Straßentopologie und –zustand, sowie besonderer Ereignisse aus- gebaut werden kann.

## Danksagung

Die Autoren danken für die Förderung durch das Bundesministerium für Wirtschaft und Ener- gie BMWi im Rahmen des Projekts „Verifikation und Validierung autonomer Systeme - VVM- methoden“ (Förderkennzeichen 19A19002K) wodurch diese Arbeit ermöglicht wurde. Ferner sei Herrn Marcus Nolte vom Institut für Regelungstechnik (IfR) der TU Braunschweig besonderes gedankt für den wertvollen Austausch und die Anmerkungen bei der Erstellung dieses Bei- trags.

## Literatur

- [1] ISO, „ISO 26262 Road Vehicle – Functional Safety, part 1-12,“ ISO, Geneva, 2018.
- [2] ISO, ISO 26262 Road Vehicles – Functional Safety, part 3: Concept Phase, Geneva: International Standardization Organization, 2018.
- [3] IEC, 61025 (DIN EN), *Fault Tree Analysis (FTA)*, Geneva: IEC, 2006.
- [4] Watson, H. A., „Launch control Safety Study,“ Bell Labs, Murray Hill, NJ, USA, 1961.
- [5] U.S. Department of Defense, „MIL-P-1629, Procedures for Performing a Failure Mode, Effects and Criticality Analysis,“ 1949.
- [6] IEC, 60812 (DIN EN), *Analysis Techniques for System Reliability - Procedure for Failure Mode and Effect Analysis (FMEA)*, Geneva: IEC, 1991.
- [7] AIAG/VDA, Failure Mode and Effects Analysis (FMEA) Handbook, AIAG and VDA QMC, 2019.
- [8] ISO/PAS 21448, „Road vehicles - Safety of the intended functionality,“ 2019.
- [9] Böde, E. et al., „Identifikation und Quantifizierung von Automationsrisiken für hochautomatisierte Fahrfunktionen - PEGASUS technischer Report,“ OFFIS Institut für Informatik, 2019. [Online]. Available:

<sup>3</sup> <https://www.safetbox.de/>

- [https://www.pegasusprojekt.de/files/tmpl/pdf/PEGASUS\\_TechnicalReport\\_Automationsrisiken\\_17.07.2019.pdf](https://www.pegasusprojekt.de/files/tmpl/pdf/PEGASUS_TechnicalReport_Automationsrisiken_17.07.2019.pdf). [Zugriff am 16.02.2021].
- [10] ISO/DIS 21448, „Road vehicles - Safety of the intended functionality,“ 2021.
  - [11] Nolte, M. et al., „Towards a Skill- And Ability-Based Development Process for Self-Aware Automated Road Vehicles,“ *IEEE 20th Int. Conf. on Intelligent Transportation Systems (ITSC)*, 2017.
  - [12] Reschka, A. et al., „Ability and skill graphs for system modeling, online monitoring, and decision support for vehicle guidance systems,“ *IEEE Intelligent Vehicles Symposium (IV)*, 2015.
  - [13] Bagschick, G. et al., „Identification of Potential Hazardous Events for an Unmanned Protective Vehicle,“ *IEEE Intelligent Vehicles Symposium*, 2016.
  - [14] Vesely, W. E., Goldberg, F., Roberts, N. H. und Haasl, D. F., „Fault Tree Handbook,“ 1981.
  - [15] Kaiser, B., Liggesmeyer, P. und Mäkel, O., „A new component concept for fault trees,“ in *Proceedings of the 8th Australian workshop on Safety critical systems and software-Volume 33*, 2003.
  - [16] Rauschenbach, M., „Probabilistische Grundlage zur Darstellung integraler Mehrzustands-Fehlermodelle komplexer technischer Systeme,“ 2017.
  - [17] Rauschenbach, M. und Nuffer, J., „Quantitative FMEA and Functional Safety Metrics Evaluation in Bayesian Networks,“ *European Conference on Reliability and Safety*, 2019.
  - [18] Bobbio, A., Portinale, L., Minichino, M. und Ciancamerla, E., „Improving the analysis of dependable systems by mapping fault trees into Bayesian networks,“ *Reliability Engineering & System Safety*, Bd. 71, pp. 249-260, 2001.
  - [19] Kaiser, B. und Rauschenbach, M., „Probabilistic Extension of Failure Net Based FMEA,“ in *European Safety and Reliability Conference ESREL*, 2015.







### OHNE PROTOTYP GEHT NICHTS IN SERIE.

Unser Podcast ist das Werkzeug, mit dem Sie Ihre Karriere in allen Phasen entwickeln – vom Studium bis zum Chefsessel. Egal, ob Sie Ingenieur\*in, Mechatroniker\*in oder Wissenschaftler\*in sind: Prototyp begleitet Sie. Alle 14 Tage hören Sie die Redaktion von INGENIEUR.de und VDI nachrichten im Gespräch mit prominenten Gästen.

**INGENIEUR.de**  
TECHNIK - KARRIERE - NEWS



# PROTO TYP

## Karriere-Podcast

**JETZT REINHÖREN UND KOSTENFREI ABONNIEREN:**  
**[WWW.INGENIEUR.DE/PODCAST](http://WWW.INGENIEUR.DE/PODCAST)**

.....  
**IN KOOPERATION MIT VDI NACHRICHTEN**









VDI-Gesellschaft  
Produkt- und Prozessgestaltung



ISBN 978-3-18-092377-2

Bildquelle: © T. Frohn