

KNN-Entwicklung in der Halbwarmumformung

D. Vasquez Ramirez, H. Wester, J. Uhe, B.-A. Behrens

Die numerische Abbildung thermomechanischer Umformprozesse erfordert hohe Rechnerleistungen. Diese können durch die Kombination von FE-Simulationen und künstlichen neuronalen Netzen (KNN) reduziert werden, insbesondere bei Prozessen, die eine Umformung und Wärmebehandlung umfassen. Es wird die Entwicklung eines KNN vorgestellt, mit dem die Materialeigenschaften einer EN AW7075 T6-Legierung nach kathodischer Tauchlackierung in Abhängigkeit von der Umformhistorie vorhersagt werden können.

STICHWÖRTER

Automobilindustrie, Umformtechnik, Künstliche Intelligenz (KI)

1 Einleitung

Durch ihr geringeres Gewicht weisen 7xxx-er Aluminiumlegierungen bei ähnlicher Festigkeit im Vergleich zu Stahl ein hohes Leichtbaupotenzial auf [1]. Aufgrund der hohen Festigkeit und geringen Duktilität ist die Umformbarkeit solcher Legierungen bei Raumtemperatur (RT) jedoch begrenzt. Eine Möglichkeit die Umformbarkeit zu verbessern ist die Erhöhung der Temperatur. Dabei erweist sich der Einsatz der Halbwarmumformung (HWU) auch vor dem Hintergrund der Energieeffizienz als vielversprechend [2].

In der Automobilindustrie besteht die Prozessroute der HWU von 7xxx-er Aluminium aus einer Erwärmung, der temperierten Umformung, dem Abschrecken im Werkzeug und einer anschließenden kathodischen Tauchlackierung (KTL). Die finalen mechanischen Eigenschaften des Bauteils werden sowohl durch den Umformprozess als auch die anschließende Wärmebehandlung während der KTL beeinflusst. Zur effizienten Prozessauslegung hat sich die FE(Finite Elemente)-Simulation etabliert. Allerdings erfordert die gekoppelte thermomechanische Betrachtung von HWU und KTL sehr hohe Rechenleistungen und -zeiten. Großes Potenzial bietet daher die Kombination von FE-Simulation und künstlichen neuronalen Netz (KNN) um spezifische Materialeigenschaften vorherzusagen [3].

In der Umformtechnik gibt es aktuell nur wenige Arbeiten, die sich mit dem Einsatz von KNN in der Umformtechnik beschäftigen, was den Forschungsbedarf in diesem Bereich verdeutlicht. Maysam *et al.* [4] entwickelten ein KNN, welches das Formänderungsverhalten eines Bleches bei einer Warmumformung anhand von virtuellen biaxialen Experimenten in Form von Spannungs-

ANN development in semi-hot forming

The numerical representation of thermomechanical forming processes requires high computing power. This can be reduced by combining FE simulation and artificial neural networks (KNN), especially for processes involving forming and heat treatment. The article presents the development of a KNN to be used for predicting the material properties of an EN AW-7075 T6 alloy after cathodic dip painting depending on the forming history.

Dehnungs-Diagrammen vorhersagen kann. Eine Veröffentlichung von Decke *et al.* [5] befasst sich mit der Vorhersage des Formänderungsverhaltens von EN AW7075 mittels KNN auf Basis von isothermen einachsigen Zugversuchen unter Variation der Temperatur bis 400 °C, der Dehnrate und des Materialzustandes.

Im Rahmen dieses Beitrags soll die Kombination von KNN mit der FE-Simulation zur Abbildung eines HWU-Prozesses bis 300 °C mit integrierter KTL vorgestellt werden. Übergeordnetes Ziel des KNN ist die Vorhersage der Materialeigenschaften einer EN AW7075 T6-Blechlegierung nach der KTL unter Berücksichtigung der thermomechanischen Prozesshistorie einer vorangegangenen HWU. Dabei soll im Gegensatz zu den vorgestellten Literaturquellen nicht nur die Umformtemperatur und die Dehnrate, sondern auch der eingebrachte Umformgrad und die Abkühlrate im Rahmen der Prozessgrenzen der HWU berücksichtigt werden. Für das Training des KNN werden experimentelle Zugversuche zur Aufbringung entsprechender thermomechanischer Belastungen unter prozessrelevanten Bedingungen durchgeführt.

2 Experimentelle Versuchsdurchführung zur Erzeugung einer Datenbasis

Für die Entwicklung und Training des KNN wurden experimentelle Daten aus uniaxialen Zugversuchen mit miniaturisierten Zugproben einer Blechdicke von 2 mm an einem Abschreck- und Umformdilatometer generiert, siehe **Bild 1 a)** und **b)**. Dabei wurden die Zugversuche zuerst unter Variation von Umformtemperatur T_{f} , Umformgrad φ , Dehnrate $\dot{\varphi}$ und Abkühlrate \dot{T}_{Ab} durchgeführt. Nach der initialen Umformung wurden die Proben bis zur RT abgekühlt und anschließend in einem Heißluftofen bei




Bild 1. a) Abschreck- und Umformdilatometer DIL 805/D+T; b) Zugprobe; c) Prozessroute Halbwarmumformung (HWU). Grafik: IFUM Hannover

Tabelle 1. Betrachtete Prozessparameter in den Zugversuchen zur Einbringung einer initialen Umformung.

Umformtemperatur T_u (°C)	125	150	175	200	225	275
Umformgrad φ (-)	0		0,05			0,1
Dehnrage $\dot{\varphi}$ (1/s)	0,01		0,1			0,1
Abkühlrate $\dot{\varphi}$ (K/s)	30		60			100

Tabelle 2. Aufbau sowie feste und variable Hyperparameter des KNN.

Input-Schicht	6 Parameter
Output-Schicht	2 Parameter
Feste Hyperparameter	
Netzwerktyp	Mehrschichtiges Feedforward neuronales Netz
Aktivierung	ReLU
Optimierer	Adam
Verlustfunktion	Mittlere quadratische Fehler
Variable Hyperparameter	
Schichten	6
Neuronen	150 pro Schicht
Lernrate	0,001
Batch-Größe	5000
Epochen	30

180 °C für 20 min erwärmt, um eine KTL abzubilden. Der KTL-Vorgang erfolgte ausschließlich an den Proben, die bei der Umformung nicht versagt haben. Abschließend wurden die vorumgeformten Zugproben nach der KTL-Behandlung am Dilatometer bei RT mit einer Dehnrage von 0,01 s⁻¹ bis zum Bruch geprüft. Somit können die mechanischen Materialeigenschaften nach KTL in Abhängigkeit von unterschiedlichen thermomechanischen Umformhistorien ermittelt werden. Die betrachtete Prozessroute ist im Bild 1 c) schematisch skizziert.

Die Versuchsdaten in Form von Spannungs-Dehnungs-Diagrammen nach der initialen Umformung wurden als Input

und diejenigen nach der KTL als Output für das KNN verwendet. **Tabelle 1** zeigt die vier Parameter, die bei der initialen Umformung der Zugproben vollfaktoriell variiert wurden. Jeder Zugversuch wurde zur statistischen Absicherung drei Mal wiederholt. Somit wurden insgesamt 486 Datensätze für das KNN generiert. Da einige Proben bereits bei der initialen Umformung versagten, reduzierte sich die verwendbare Anzahl für den Output auf 432 Spannungs-Dehnungs-Diagramme.

3 Aufbau und Verifizierung des KNN

Um eine unabhängige Open Source Lösung zu entwickeln, wurde für die Modellierung und das Training des KNN die Programmiersprache Python in der Entwicklungsumgebung Spyder verwendet. Als Netztyp wurde ein Feed-Forward neuronales Netz ausgewählt, in dem die Informationen von Input in Richtung Output ohne Rückkopplungen laufen. Das Netz wurde aus sechs Input- und zwei Output-Parametern aufgebaut. Als Input wurden die initialen Umformparameter (T_u , φ , $\dot{\varphi}$, \dot{T}_{Ab}) sowie Spannung und Dehnung vor KTL, als Output Spannung und Dehnung nach KTL definiert (Bild 1 c). 80 % der Gesamtdaten wurden für das Training, 10 % für die Validierung und 10 % für das Testing verwendet. Die Trainingsdaten dienen zum Aufbau des Berechnungsalgorithmus zwischen den Input-, Output- und Zwischenschichten. Die Validierungsdaten dienen zur Bestimmung der Vorhersagegenauigkeit des trainierten Netzes bei gleichzeitiger Anpassung der variablen Hyperparameter, wobei für die experimentellen Inputdaten der Output vom KNN vorhergesagt wurde. Zur abschließenden Überprüfung der Vorhersagegenauigkeit ohne Anpassung der Hyperparameter wurde der Testdatensatz verwendet, bei dem analog zum Validierungsdatensatz der Output der experimentellen Inputdaten durch KNN vorhergesagt wurde. Durch den Vergleich des vorhergesagten und experimentellen Outputs wurde die Vorhersagegenauigkeit sowohl der Validierungs- als auch der Testdatensätze bestimmt [4].

Ein KNN besteht grundsätzlich aus festen und variablen Hyperparametern, dargestellt in **Tabelle 2**.

Im Folgenden werden die festen Hyperparameter vorgestellt. Da das Lernen des KNN auf einem stochastischen Gradientenabstiegsverfahren basiert, ist eine differenzierbare Aktivierungsfunktion erforderlich. Als Aktivierungsfunktion wurde die ReLU-Funktion (englisch: Rectified Linear Units) ausgewählt, welche in der Input- und Zwischenschicht implementiert wurde [6]. Ein weiterer fester Hyperparameter, der Optimierungsalgorithmus,




Bild 2. a) Genauigkeit und b) MSE (Mean Square Error)-Wert über die Epochen zur Beurteilung der Vorhersagegenauigkeit des künstlichen neuronalen Netzes (KNN) bei Trainings- und Validierungsdaten. Grafik: IFUM Hannover

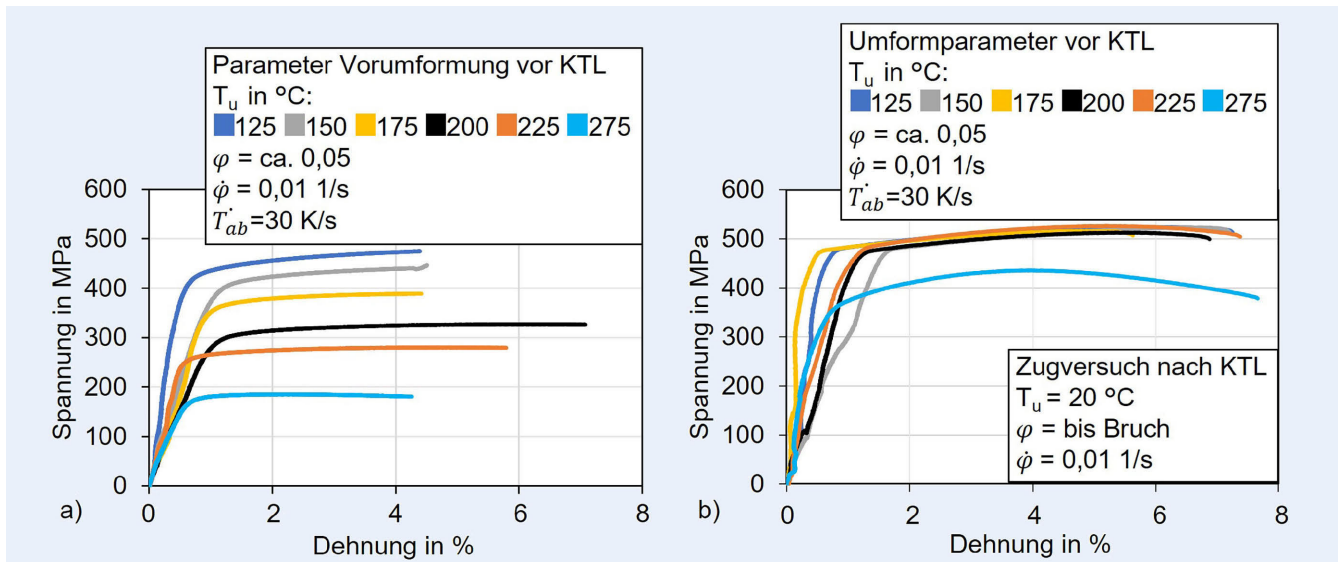


Bild 3. Spannungs-Dehnungs-Diagramme von a) vorumgeformten Zugproben vor der kathodischen Tauchlackierung (KTL)-Behandlung und b) bis zum Bruch geprüften Zugproben nach der KTL-Behandlung. Grafik: IFUM Hannover

dient zur iterativen Berechnung individueller adaptiver Lernraten für verschiedene Parameter, in diesem Fall für die Biases und Gewichten des Netzes, basierend auf dem Trainingsdatensatz. Somit wirkt Adam (englisch: ADaptive Moment estimation) als die Optimierung einer skalar parametrisierten Zielfunktion, die eine Maximierung oder Minimierung in Bezug auf die Parameter, Input- und Zielgrößen durchführt [7].

Die variablen Hyperparameter wurden durch die Variation der einzelnen Werte bestimmt, bis die angestrebten Grenzwerte der Genauigkeit und des mittleren quadratischen Fehlers (englisch: Mean Square Error – MSE) erreicht wurden [3]. Dies enthält die Anzahl der Schichten und Neuronen pro Schicht, welche als Grundkonstruktion des Netzes dienen, sowie die Lernrate, die die Schrittgröße der Fehlerminimierung bestimmt. Dazu gehören auch die Batch-Größe, welche die Anzahl der Trainingsdaten in einem Durchlauf definiert, und die Epochen, welche die Anzahl der Durchläufe aller Trainingsdaten in der entsprechenden Batch-Größe beschreiben [3].

Anhand der Genauigkeit der Vorhersage sowie des MSE wurden die festen und variablen Hyperparameter ermittelt und verifiziert. In **Bild 2** a) und b) sind jeweils die Genauigkeit und der

MSE-Wert über die Epochen für die Trainings- und Validierungsdaten dargestellt. Die Genauigkeit beschreibt die Präzision der Vorhersagen beim Training und bei der Validierung. Es wird eine höchstmögliche Genauigkeit angestrebt. Der MSE-Wert gibt die quadratische Differenz zwischen den experimentellen und den vom KNN vorhergesagten Ergebnissen beim Training und bei der Validierung an. Ziel ist ein möglichst geringer MSE-Wert. Mit den ausgewählten festen und variablen Hyperparametern konnte eine Genauigkeit von 94% und ein MSE-Wert von 0,03 erreicht werden, was auf ein sehr gut trainiertes Netz hindeutet [3].

4 Ergebnisse

Bild 3 a) zeigt exemplarisch einige Spannungs-Dehnungs-Diagramme von vorumgeformten Zugproben vor der KTL.

Demgegenüber sind in **Bild 3** b) die Spannungs-Dehnungs-Diagramme der vorumgeformten und KTL behandelten Zugproben gestellt, die anschließend bis zum Bruch geprüft wurden. Die Definition der Prozessroute (**Bild 1** c) erfolgte anhand der in **Tabelle 1** dargestellten Parameter. Es werden exemplarisch Span-

Tabelle 3. Temperaturabhängige Kennwerte der Streckgrenze, Zugfestigkeit und Restdehnung von vorumgeformten Zugproben vor KTL im Bild 3 a) und bis zum Bruch geprüften Zugproben nach KTL im Bild 3 b).

T in °C	Vor KTL		Nach KTL		
	Streckgrenze $R_{p0,2\%}$ in MPa	Zugfestigkeit R_m in MPa	Streckgrenze $R_{p0,2\%}$ in MPa	Zugfestigkeit R_m in MPa	Restdehnung A_{res} in %
125	434,7 ± 12,4	467,4 ± 8,1	484,9 ± 3,4	516,01 ± 9,3	8,5 ± 1,1
150	393,5 ± 4,7	430,4 ± 13,9	482,9 ± 2,3	520,1 ± 3,8	8,1 ± 0,9
175	350,2 ± 13	384,7 ± 8,9	480,1 ± 7,8	510,6 ± 6,5	6,4 ± 1,2
200	297,5 ± 1	325,2 ± 1,5	477,8 ± 8,7	517,7 ± 11,1	6,3 ± 2
225	259,9 ± 0,5	282,5 ± 1,7	483,1 ± 6	523,5 ± 6,4	6 ± 1
275	179,6 ± 6,5	184,1 ± 1	377,9 ± 14,7	408,6 ± 30,7	6,1 ± 1,6

nungs-Dehnungs-Diagramme unter Variation der Umformtemperatur, zwischen 125 und 275 °C, gezeigt, wobei der Umformgrad, die Dehn- und die Abkühlrate der initialen Umformung konstant gehalten wurden. Die Farben der Spannungs-Dehnungs-Verläufe in Bild 3 b entsprechen den Parametern der initialen Umformung zur physikalischen Simulation des thermomechanischen Umformprozesses vor der KTL in Bild 3 a).

Zunächst zeigt sich, wie zu erwarten, ein deutlicher Einfluss der Umformtemperatur auf das Formänderungsverhalten (Bild 3 a). Mit steigender Temperatur sinkt die resultierende Spannung deutlich. Die Analyse der vorumgeformten und danach KTL-behandelten Proben zeigt dahingegen nur einen geringen Einfluss der vorangegangenen Umformhistorie auf die finalen mechanischen Eigenschaften für die betrachteten Umformparameter (Bild 3 b). Mit Ausnahme der bei 275 °C vorumgeformten Probe liegt sowohl die Zugfestigkeit als auch die Restdehnung nach KTL auf einem vergleichbaren Niveau. Somit zeigt eine Variation der Umformtemperatur bis einschließlich 225 °C unter konstanten Umformparametern keinen signifikanten Einfluss auf die finalen mechanischen Eigenschaften.

Die bei 275 °C vorumgeformte Probe weist ein deutlich geringeres Spannungsniveau auf. Diese Entfestigung kann durch stark vergrößerte Ausscheidungen aufgrund der vergleichsweise hohen Umformtemperatur verursacht werden. Hierbei tritt ein starker Härteabfall und somit auch eine Festigkeitsverringerung auf [8]. Eine solche Bildung vergrößerter Ausscheidungen wurde in einer ähnlichen Untersuchung der Legierung EN AW7075 T6 bereits bei 250 °C beobachtet [9]. Gleichartiges Werkstoffverhalten konnte bei den Zugversuchen mit Vorumformgraden von 0 und 0,1 beobachtet werden (siehe Tabelle 2). Zum genaueren Vergleich sind in **Tabelle 3** die temperaturabhängigen Kennwerte der Streckgrenze, Zugfestigkeit und Restdehnung der in Bild 3 a) und b) dargestellten Spannungs-Dehnungs-Diagramme jeweils vor und nach KTL angegeben.

Durch die Umformung vor KTL und die anschließende KTL-Behandlung wurden allerdings die Grundmaterialeigenschaften deutlich verändert. Die unbehandelte Referenzzugprobe, geprüft bis zum Bruch bei RT und $0,01 \text{ s}^{-1}$, erreichte eine Zugfestigkeit von 553,1 MPa und eine Restdehnung von 11 %. Somit wurde die Zugfestigkeit durch die Halbwarmumformung und anschließende KTL-Behandlung bei Temperaturen zwischen 125–225 °C um circa 30 MPa und bei 275 °C um circa 140 MPa gegenüber der Referenz reduziert. Die verbleibende Restdehnung bis zum Bruch wurde bei allen vorumgeformten Proben trotz der unter-

schiedlichen Umformtemperaturen auf circa 8–6 % Restdehnung im Vergleich zu der Referenz reduziert.

Die vor und nach KTL erzeugten Spannungs-Dehnungs-Diagramme wurden jeweils als Input und Output für das KNN verwendet, das mit den Parametern in Tabelle 2 entwickelt wurde. Nach dem erfolgreichen Training des Netzes, wie in Kapitel 3 beschrieben, erfolgte die Verifizierung der Netzvorhersage durch die Gegenüberstellung der vorhergesagten und experimentellen Validierungsdaten nach KTL für verschiedene Umformparameter, veranschaulicht im **Bild 4**.

Bild 4 a) und b) zeigen eine sehr gute Übereinstimmung der vorhergesagten Spannungs-Dehnungs-Diagramme mit den experimentellen Ergebnissen. Dabei konnte eine gute Identifikation der Hookeschen Gerade sowie eine sehr gute Vorhersage der Zugfestigkeit erreicht werden. Allerdings ist die Abweichung der vorhergesagten Restdehnung im Verhältnis zur vorhergesagten Zugfestigkeit deutlich höher, was auf eine größere Streuung der experimentellen Daten hinsichtlich der Restdehnung im Vergleich zur Zugfestigkeit zurückzuführen ist. Die Spannungs-Dehnungs-Diagramme in Bild 4 c) und d) zeigen hingegen eine stark von den Experimenten abweichende Vorhersage.

Der Grund liegt in der Qualität der Daten. Die Verwendung von experimentellen Ergebnisdaten, die eine starke Streuung aufwiesen, hat zu ungenauen Ergebnissen geführt. Die Material- und Messschwankungen äußern sich vor allem in einer streuenden Restdehnung sowie nicht-linearen Verläufen der Hookeschen Gerade, wie in den experimentellen Verläufen in Bild 4 c und d zu sehen. Bei der Messung der Längenänderung des elastischen Bereichs treten teilweise Schwankungen aufgrund der Trägheit der Schubstangen auf. Diese sind im Verlauf der Hookeschen Gerade sichtbar.

Zudem konnte bei der Versuchswiederholung bei geringen Dehnraten und Umformgraden keine gute Reproduzierbarkeit des Umformgrades und somit der Restdehnung gewährleistet werden. Bei diesen Versuchsparametern lag die hydraulische Zugregelung, gesteuert durch die Ziel-Längenänderung, an der untersten Grenze. Daher wurde bei der Restdehnung eine hohe Ergebnisstreuung in den Versuchswiederholungen festgestellt. Somit wurde gezeigt, dass die Qualität der Daten einen größeren Einfluss auf die Vorhersagegenauigkeit als die Quantität besitzt. Dennoch konnte anhand der dargestellten Ergebnisse in Bild 4 a und b gezeigt werden, dass ein trainiertes KNN in der Lage ist, vollständige Spannungs-Dehnungs-Diagramme als Input zu

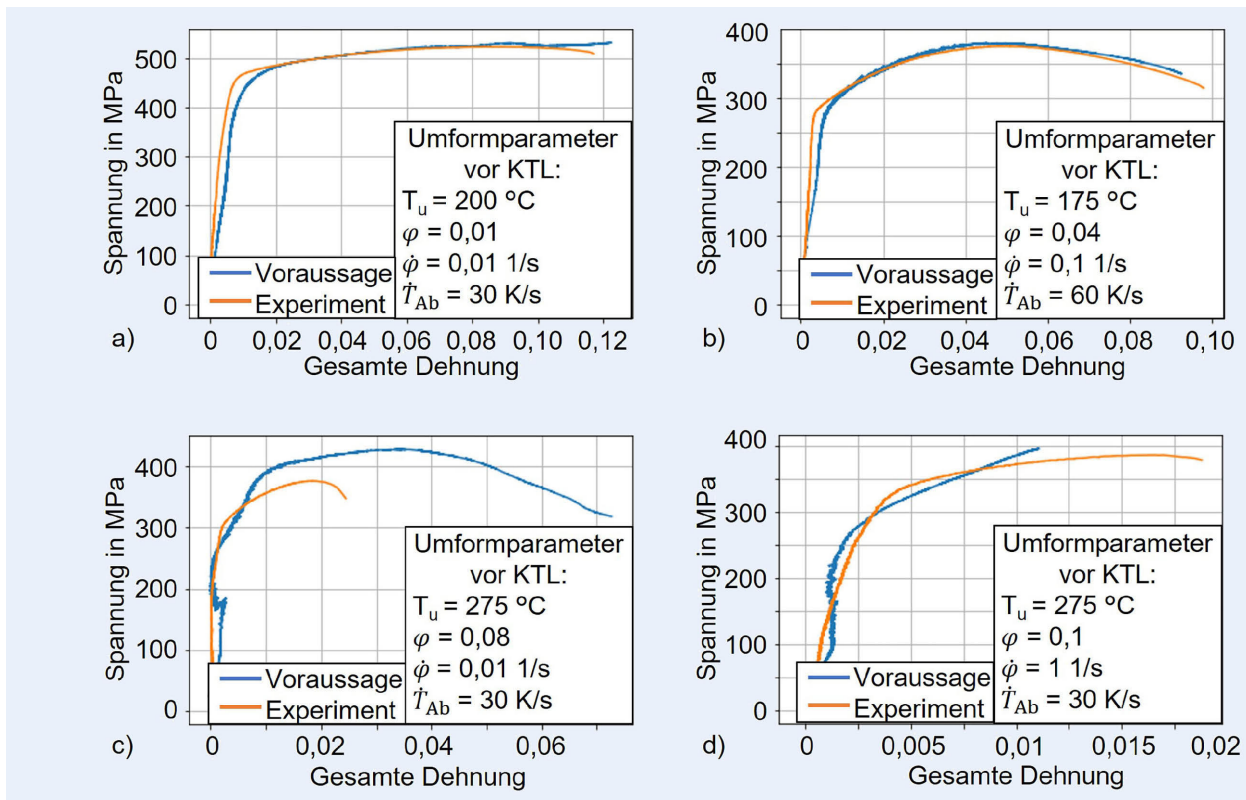


Bild 4. Vom KNN vorhergesagte und experimentell ermittelte Spannungs-Dehnungs-Diagramme für verschiedene Umformparameter nach KTL.
Grafik: IFUM Hannover

erkennen und ebenfalls als Output in Abhängigkeit von den Umformparametern vorherzusagen.

5 Fazit und Ausblick

In dieser Studie wurde die Modellierung und das Training eines mehrschichtigen Feedforward künstlichen neuronalen Netzes mit dem Ziel vorgenommen, die finalen mechanischen Materialeigenschaften in Abhängigkeit der thermomechanischen Umformhistorie vorherzusagen. Dies erfolgte am Beispiel einer Prozesskette der Halbwarmumformung mit integrierter kathodischer Tauchlackierung für die hochfeste Aluminiumlegierung EN AW7076 T6.

Zur Ermittlung der Materialeigenschaften wurden Versuchsdaten in Form von Spannungs-Dehnungs-Diagrammen aus

experimentellen Zugversuchen an einem Umformdilatometer entsprechend der Prozessroute einer Halbwarmumformung erzeugt. Die Spannungs-Dehnungs-Diagramme nach einer initialen Umformung sowie die verwendeten Umformparameter dienen als Input. Die Spannungs-Dehnungs-Diagramme nach der kathodischen Tauchlackierung, welche die finalen mechanischen Materialeigenschaften beschreiben, wurden als Output verwendet. Insgesamt konnte das entwickelte neuronale Netz die Zugfestigkeit sehr gut vorhersagen. Die Bestimmung der Restdehnung sowie die genaue Nachbildung der Hookeschen Gerade zeigte aber teilweise deutliche Abweichungen von den Experimenten. Die ist zum einen auf die Streuungen des Materials hinsichtlich der Restdehnung zurückzuführen, welche in den drei Wiederholungsversuchen beobachtet wurden. Zum anderen führen Messschwan-

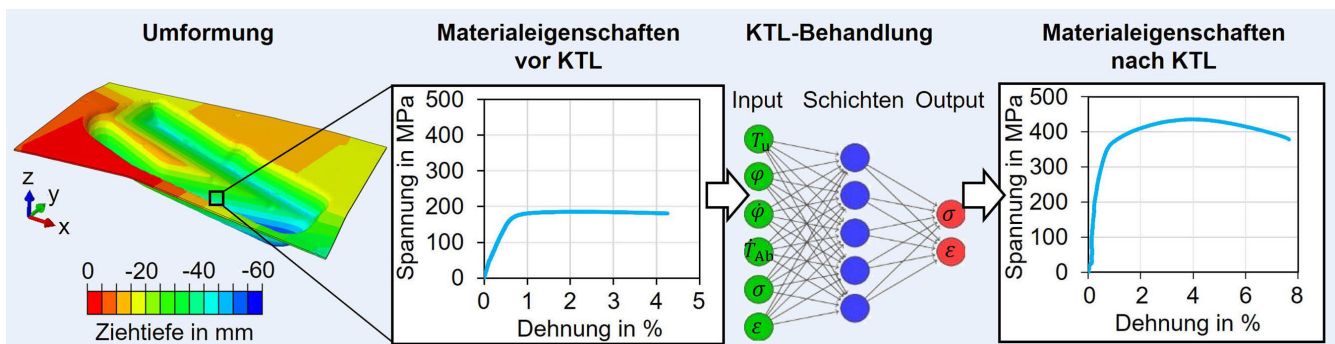


Bild 5. Kombination zwischen dem Finite-Elemente-Modell einer HWU und dem vollständig entwickelten KNN zur Vorhersage der mechanischen Materialeigenschaften nach KTL in Abhängigkeit von der Umformhistorie. Grafik: IFUM Hannover

kungen wie ein nicht linearer Verlauf der Hookeschen Gerade zu falschen Vorhersagen.

Zusammenfassend konnte festgestellt werden, dass die Datenqualität einen größeren Einfluss auf die Vorhersagegenauigkeit hat als die Datenmenge. Aus diesem Grund wird für die weitere Entwicklung des KNN eine automatisierte Vorprüfung der Datenqualität umgesetzt, um die Qualität des KNN weiter zu steigern. Des Weiteren wird das entwickelte künstliche neuronale Netz mit dem FE-Modell des Halbwarmumformprozesses kombiniert, sodass die Materialeigenschaften nach der kathodischen Tauchlackierung in Abhängigkeit von der Umformhistorie vorhergesagt werden können, wie in **Bild 5** veranschaulicht.


DANKSAGUNG

Die Autoren bedanken sich bei den Forschungsförderer, dem Bundesministerium für Wirtschaft und Energie. Die Finanzierung wurde von der Arbeitsgemeinschaft industrieller Forschungsvereinigungen (AiF) im Rahmen eines Programms für industrielle Gemeinschaftsforschung (IGF) unter der Förderkennziffer 21645N organisiert.

Literatur

- [1] Lin, J.; Bao, X.; Hou, Y. et al.: Investigation on Yield Behavior of 7075-T6 Aluminum Alloy at Elevated Temperatures. Chinese Journal of Mechanical Engineering 33 (2020) 1, p. 76
- [2] Pandya, K. S.; Roth, C. C.; Mohr, D.: Strain Rate and Temperature Dependent Plastic Response of AA7075 during Hot Forming. IOP Conference Series: Materials Science and Engineering 651 (2019) 1, p. 12100
- [3] Kohar, C. P.; Greve, L.; Eller, T. K. et al.: A machine learning framework for accelerating the design process using CAE simulations: An application to finite element analysis in structural crashworthiness. Computer Methods in Applied Mechanics and Engineering 385 (2021), #114008
- [4] Maysam B. G.; Dirk M.: Towards neural network models for describing the large deformation behavior of sheet metal. IOP Conference Series: Materials Science and Engineering 651 (2019) 1, #12102
- [5] Decke, J.; Engelhardt, A.; Rauch, L. et al.: Predicting Flow Stress Behavior of an AA7075 Alloy Using Machine Learning Methods. Crystals 12 (2022) 9, doi.org/10.17170/kobra-202304217875
- [6] Lin, Y. C.; Zhang, J.; Zhong, J.: Application of neural networks to predict the elevated temperature flow behavior of a low alloy steel. Computational Materials Science 43 (2008) 4, pp. 752–758
- [7] Kingma, D. P.; Ba, J.: Adam: A method for stochastic optimization. arXiv preprint arXiv:1412 (2014), #6980, doi.org/10.48550/arXiv.1412.6980
- [8] Behrens, B.-A.; Vogt, H.; Jalanesh, D. M. et al.: Warmumformung von 7xxx-Aluminiumlegierungen. EFB-Forschungsbericht Nr. 501. Stand: 2018. Internet: www.gbv.de/dms/tib-ub-hannover/1049514572.pdf. Zugriff am 22.09.2023
- [9] Wangtu H.; Longgang H.; Yusheng Z. et al.: Warm formability and post-forming microstructure/property of high-strength AA 7075-T6 Al alloy. Materials Science and Engineering: A 675 (2016), pp. 44–54



Dominyka Vasquez Ramirez, M.Sc. 
Foto: IFUM

Hendrik Wester, M.Sc. 

Dr.-Ing. **Johanna Uhe** 

Prof. Dr.-Ing. **Bernd-Arno Behrens** 

Leibniz Universität Hannover
Institut für Umformtechnik und Umformmaschinen (IFUM) [0304hq317]
An der Universität 2, 30823 Garbsen
Tel. +49 511 / 762-161
vasquezramirez@ifum.uni-hannover.de
www.ifum.uni-hannover.de

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons Namensnennung 4.0 International (CC BY 4.0)