

Bestimmung von mechanischen Blechkennwerten durch Maschinelles Lernen im offenen Beschnitt

Einsatz von ML beim Scheren im offenen Schnitt

M. Görz, A. Schenek, M. Liewald, K. R. Riedmüller

Die Qualität der durch Umform- und Schneidprozesse hergestellten Bauteile wird durch schwankende mechanische Eigenschaften des verwendeten Blechmaterials beeinflusst. In dieser wissenschaftlichen Veröffentlichung wird eine neuartige, auf maschinellem Lernen basierende Methode zur Inline-Bestimmung von Werkstoffkennwerten vorgestellt. Diese soll es erlauben, die mechanischen Kennwerte direkt aus den im offenen Schnitt gemessenen Schneidkraftverläufen zu ermitteln.

STICHWÖRTER

Schneiden, Künstliche Intelligenz (KI), Digitalisierung

Use of ML in shearing with an open cutting line

The quality of components produced by forming and stamping processes is affected by fluctuating mechanical properties of the sheet metal material. This scientific publication presents a novel method based on machine learning for the inline determination of material properties. It enables the determination of mechanical properties directly from the punching force curves measured when shearing with an open cutting line.

1 Einleitung und Motivation

Bei der Herstellung von Blechbauteilen werden meist mehrere Scher- und Umformoperationen kombiniert. Die Qualität der erzielten Bauteile hängt dabei stark von den Werkstoffparametern der verwendeten Halbzeuge ab. Typische Fehler, wie zum Beispiel das Reißen [1] der Teile beim Tiefziehen oder ein verändertes Rückfederungsverhalten des Fertigteils [2], können dabei in vielen Fällen direkt mit schwankenden Werkstoffparametern in Verbindung gebracht werden [3]. Auch haben Untersuchungen im BMW-Presswerk Dingolfing gezeigt, dass solche chargenbedingten Abweichungen der Materialparameter des Blechhalbzeugs nach wie vor eine Hauptursache für Qualitätsverluste und Prozessausfälle bei der Herstellung von Blechbauteilen sind [4]. Dabei können die mechanischen Werkstoffeigenschaften über die Coillänge [5] wie auch über die Coilbreite [6] schwanken. Um eine Null-Fehler-Produktion zu erreichen, wird daher versucht, schwankende Materialeigenschaften möglichst in Echtzeit und inline zu bestimmen. Allerdings sind die meisten der heute eingesetzten Messverfahren zur Bestimmung von Materialparametern nicht in der Lage, Materialkennwerte in situ zu messen.

Wegen der begrenzten Fähigkeit traditioneller Methoden zur Inline-Materialcharakterisierung wurden verschiedene neuartige Verfahren entwickelt, mit denen potenziell Materialeigenschaften in situ bestimmt werden können. Ružović nutzt beispielsweise die Korrelation von mechanischen Eigenschaften des Materials mit durch das Wirbelstromverfahren gemessenen elektromagnetischen Eigenschaften, um entsprechende Werkstoffkennwerte zu bestimmen [7]. Diese Messmethode weist neben einer Sensitivität für Bandschwingungen und Verschmutzungen weitere Nachteile auf. So kann dieses Messprinzip nur für Stahlwerkstoffe ange-

wendet werden. Ferner haben Wiesenmayer *et al.* die Werkstoffparameter mittels linearer Korrelationen auf Basis von im Prozess gemessenen Schneidkraftverläufen bestimmt. Die Schneidkraftverläufe wurden durch Scheren im geschlossenen Schnitt bestimmt. Diese Untersuchungen wurden jedoch nur für den Werkstoff DP600 durchgeführt [8].

Darüber hinaus wurde am Institut für Umformtechnik (IFU) ein neuartiges Verfahren zur Inline-Materialcharakterisierung basierend auf maschinellem Lernen (ML) entwickelt, das auf dem Einsatz von Künstlichen Neuronalen Netzen (KNN) beruht [9, 10]. Mit einem vortrainierten KNN werden hierbei Korrelationen zwischen dem Kraftbedarf für das Scherschneiden eines Bleches mit einem Rundstempel und dem Spannungs-Dehnungs-Diagramm des entsprechenden Blechwerkstoffes genutzt, um dessen mechanische Kennwerte vorherzusagen. Die Autoren konnten zeigen, dass ein derart vortrainiertes KNN präzise Vorhersagen der Materialparameter erlaubt. Dabei wurde die vorgeschlagene Methode zur Inline-Materialcharakterisierung bislang ausschließlich für Schneidprozesse mit kreisrunder (geschlossener) Schnittlinie erprobt. Konkrete Anwendungsfelder ergeben sich hierbei zum Beispiel für Positionslochungen, welche in schnelllaufenden Stanzwerkzeugen zur Ausrichtung des Blechstreifens verwendet werden. Im Großwerkzeugbau befinden sich entsprechende Lochgruppen zumeist tief im Inneren der Umformwerkzeuge, weshalb ein einfaches Nachrüsten der Werkzeuge mit der notwendigen Sensorik zur Messung des Schneidkraftbedarfs aus geometrischen Gründen (Platzbedarf, Kabelführung, etc.) oft nur schwer umsetzbar ist. Geometrisch zugänglicher sind meist die weiter außen liegenden Schneidmesser, welche für den Beschnitt der Bauteilumrandungen eingesetzt werden.

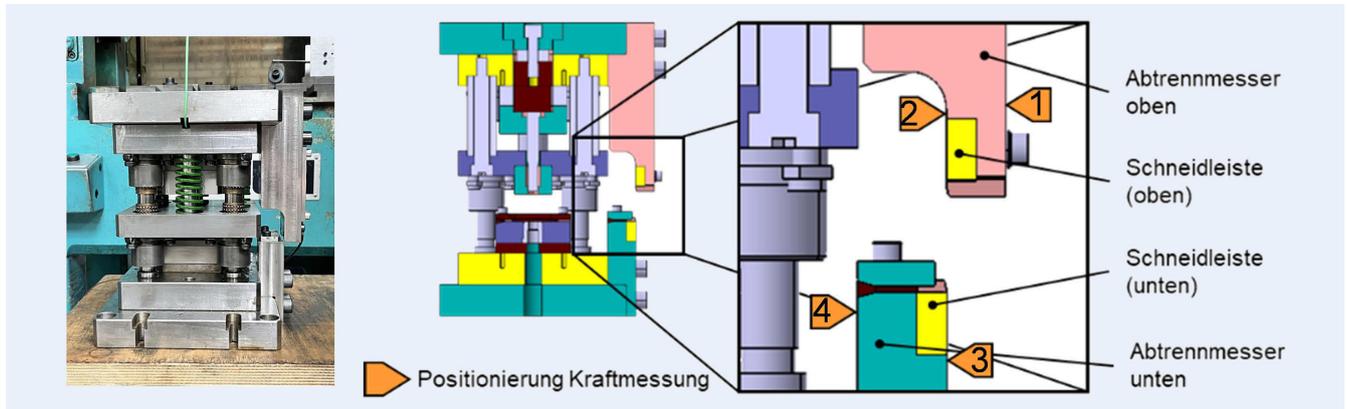


Bild 1. Versuchswerkzeug (links), Rendering des Versuchswerkzeugs in Schnittdarstellung mit eingezeichneten möglichen Sensorpositionen (rechts).
Foto: IFU

Eine weitere Möglichkeit besteht in der Implementierung der vorgeschlagenen Methode beim Platinenbeschnitt auf einer Platinschneidanlage. Eine direkte Schneidkraftmessung ist an den dabei eingesetzten Schneidmessern meist nicht möglich, weshalb eine indirekte Messung durch beispielsweise Dehnungsmessstreifen (DMS) erfolgen muss. In den vorgestellten Untersuchungen wurde daher analysiert, inwiefern die Bestimmung von Werkstoffkennwerten auch auf Basis einer solchen indirekten Kraftmessung an Schneidmessern möglich ist. Dazu wurde ein am IFU vorhandenes Schneidwerkzeug mit DMS ausgerüstet und damit die Deformation der Abtrennmesser im offenen Schnitt aufgezeichnet. Anhand dieser Daten und im Zugversuch bestimmter mechanischer Werkstoffkennwerte wurde danach ein ML-Modell trainiert und evaluiert. In den folgenden Abschnitten wird gezeigt, dass der gewählte ML-basierte Ansatz eine vielversprechende neue Methode für die Inline-Charakterisierung von mechanischen Blechwerkstoffkennwerten anhand des Kraftbedarfs beim offenen Platinenbeschnitt ist.

2 Methodik

Die in diesem Beitrag vorgestellten Untersuchungen basieren auf dem KDT-EA (Knowledge Discovery in Time Series for Engineering Applications)-Prozess [11, 12]. Dieses Vorgehensmodell wurde entwickelt, um eine erfolgreiche Umsetzung zur Anwendung von ML-Modellen auf Basis von Zeitreihendaten zu gewährleisten. Der Prozess besteht aus fünf separaten Teilschritten, in denen beschrieben wird, wie Daten erfasst, vorbereitet, transformiert, als Eingangsgrößen für Modelle verwendet und schließlich die Ergebnisse der Modelle bewertet werden.

Für die im Folgenden beschriebenen Analysen und die Verarbeitung der erfassten Versuchsdaten wurde die Programmiersprache Python verwendet. Um Schneidkraftkurven oder daraus abgeleitete Features mit mechanischen Blechparametern zu korrelieren, wurden die Deep-Learning-Bibliotheken „TensorFlow“ (TF) und „Keras“ verwendet. Die Library Keras vereinfacht durch zusätzliche Tools und Funktionen das Training von ML-Modellen. Weitere Python-Bibliotheken, die für die vorgestellten Untersuchungen verwendet wurden, sind „Numpy“ zur Datenaufbereitung, „Matplotlib“ zum Plotten der Daten, „Pandas“ zum Auslesen von Daten aus Messprotokollen und „Scikit-learn“ zur Durchführung von Principal Component Analysis (PCA), Standardisierung und Normalisierung.

3 Datenerfassung, Datenvorbereitung und Datentransformation

Die Zugversuche zur Ermittlung der mechanischen Werkstoffkennwerte (R_m , $R_{p0.2}$, R_e , A_v , A_G , n) der in den hier beschriebenen Untersuchungen betrachteten Blechwerkstoffe (DP600, DP800, DP1000, DP1200) wurden auf einer „Roell + Korthaus RKM 100“ Universalprüfmaschine nach DIN EN ISO 6892-1 durchgeführt. Die Zugproben wurden nach DIN 50125 im Format $H20 \times 80$ hergestellt. Schließlich wurden die mittels dieser Versuche ermittelten Materialkennwerte (R_m , $R_{p0.2}$, R_e , A_v , A_G , n) als Zielgrößen für das spätere ML-Modell verwendet.

Die Bestimmung der Eingangsgrößen für das spätere ML-Modell erfolgte mit einem am IFU vorhandenen Schneidwerkzeug. **Bild 1** zeigt das Schneidwerkzeug im Original und als Rendering in der Schnittdarstellung.

Die eingefügte Detailzeichnung zeigt das obere und untere Abtrennmesser und die daran angebrachten Schneidleisten. Die markierten Bereiche 1 bis 4 wurden als potenzielle Bereiche zur Integration eines Dehnungsmessensors anhand konzeptioneller Vorüberlegungen identifiziert. Aufgrund der Gefahr des Abschrens des Sensors durch das Schneidwerkzeug und der schlechten Zugänglichkeit wurden die Positionen 2, 3 und 4 in den hier vorgestellten Untersuchungen nicht weiter betrachtet. Im realen Versuchswerkzeug wurde der Sensor daher auf der Außenseite des Werkzeugs an Position 1 angebracht.

Zur Festlegung der Empfindlichkeit des Sensors und des notwendigen Messbereiches wurde eine Finite-Elemente-Simulation (FE) des Scherschneidens durchgeführt. Ziel dieser Simulation war es, die im oberen Abtrennmesser auftretenden Dehnungen zu bestimmen und auf Basis dieser Dehnungen einen geeigneten DMS auszuwählen. Um eine konservative Abschätzung treffen zu können, wurde der Versuchswerkstoff mit der geringsten Festigkeit (DP600) für diese Simulationen verwendet, da er die geringsten Prozesskräfte und dadurch die geringsten Dehnungen im oberen Abtrennmesser hervorruft. Der Aufbau eines numerischen Simulationsmodells für das Scherschneiden zur Analyse der im oberen Abtrennmesser auftretenden Dehnungen wurde in der Simulationssoftware „Deform 2D“ vorgenommen. Die Werkzeugkomponenten Obermesser, Untermesser und Abstreifer wurden als nicht-deformierbare Starrkörper modelliert. Die Vernetzung der Platine wurde durch lokale Netzverfeinerung mit einer kleinsten Elementkantenlänge von circa $1,5 \mu\text{m}$ ausgeführt. Das

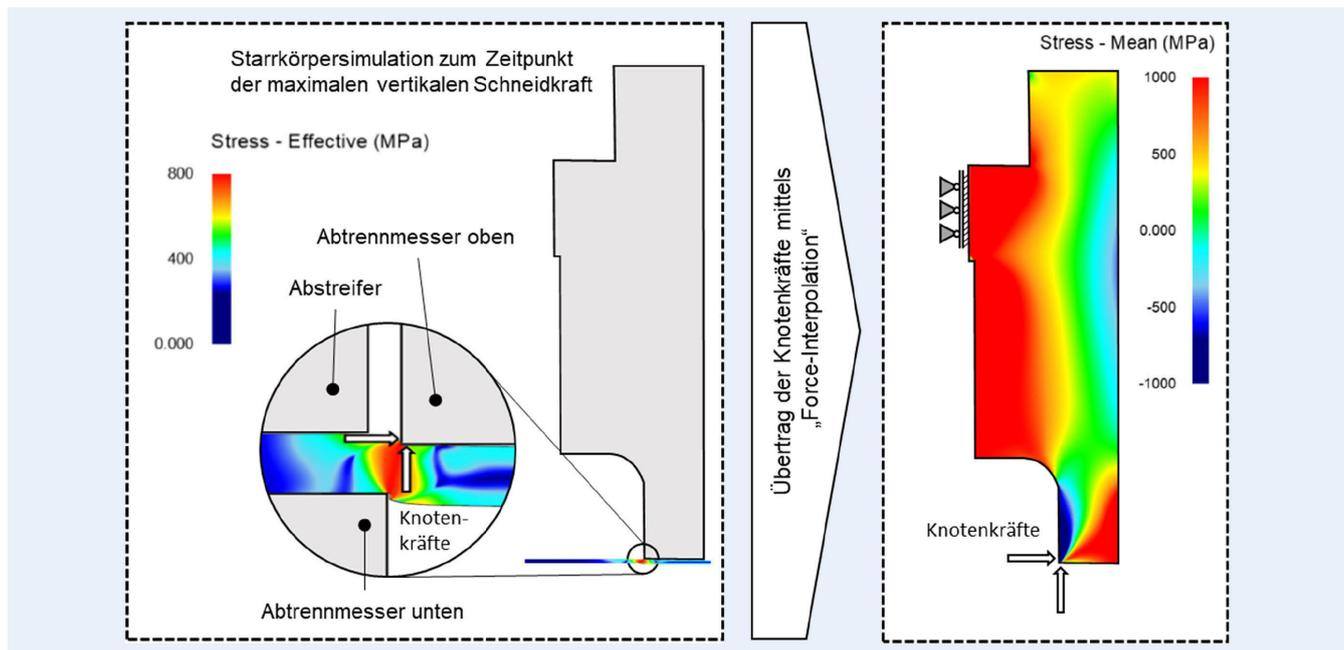


Bild 2. Methode zur Bestimmung der Dehnungen am Abtrennmesser oben. Grafik: IFU

Materialverhalten der Platine wurde elastisch-plastisch modelliert. Um die beim Scherschneiden auftretenden Trenn- und Fließvorgänge präzise darzustellen, wurde die Fließkurve im einachsigen Zugversuch bestimmt und diese ab der Gleichmaßdehnung mittels Extrapolation nach Hockett-Sherby erweitert. Zur Abbildung des blechwerkstoffspezifischen Fließ- und Trennverhaltens wurde das Schädigungsmodell „Normalized Cockroft Latham“ eingesetzt und invers durch einen Abgleich mit experimentell ermittelten Schnittflächenanteilen validiert. Die Schnittflächenanteile wurden dabei durch optische Konturmessungen und metallurgische Schlitze bestimmt. Im Abgleich von Experiment zu Simulation wurde eine geringe Abweichung von circa 5 % festgestellt.

Mit dem so kalibrierten Simulationsmodell wurde dann die zu erwartende maximale Stempelkraft und die resultierende maximale Dehnung des oberen Abtrennmessers berechnet. Dafür wurde im Anschluss an die konventionelle Scherschneidsimulation mit Starrkörpern eine „Die Stress Study“ durchgeführt. Im Zuge dieser Simulationsmethode wurde der Starrkörper des Schneidmessers durch einen elastischen und vernetzten Körper (E-Modul: 210 GPa) ersetzt. Die in der Starrkörpersimulation berechneten Knotenkräfte wurden dann mittels Force-Interpolation auf den elastischen Körper übertragen. Somit war es möglich, die im Schneidmesser auftretenden Dehnungen für einen Zeitschritt der Starrkörpersimulation zu bestimmen. Um die maximal auftretende vertikale Dehnung im Schneidmesser zu bestimmen, wurde der Zeitschritt mit der maximal vertikalen Schneidkraft ausgewählt. Bild 2 zeigt das Ergebnis der „Die Stress Study“ für das obere Abtrennmesser, wobei die berechneten Dehnungen im Falschfarbenplot dargestellt sind.

Wie zu sehen, stellt sich im Bereich 1 eine konstante negative Dehnung über einen großen Bereich des Obermessers ein. Die Dehnungsbeträge befinden sich im Wertebereich von $-1,00e^{-4}$ bis $-2,00e^{-4}$. Auf Basis dieser Simulationsergebnisse wurde der Sensor SLB700A/06VA1 der Firma HBM ausgewählt, welcher einen

Nennmessbereich von 0 bis $5,00e^{-4}$ mm/mm und einen minimalen Arbeitsbereich von 0 bis $5,00e^{-5}$ mm/mm aufweist [13].

Mit dem zur Dehnungsmessung befähigten Werkzeug wurden sodann experimentelle Untersuchungen zur Bestimmung der Dehnung im oberen Abtrennmesser durchgeführt. Die Messung der Dehnung im oberen Abtrennmesser wurde mit einer Frequenz von 19 kHz ausgeführt. Der Schneidspalt der Schneidstufe wurde auf 10 % eingestellt und die Verrundung der Schneidleiste mit $20 \mu\text{m}$ ausgeführt. Diese Parameter waren für alle beschriebenen Untersuchungen konstant. Für jeden Blechwerkstoff wurden mehrere Wiederholungen durchgeführt, so dass insgesamt ein Datensatz mit circa 700 Messungen erstellt wurde. Die aufgezeichneten Kurven wurden anschließend mit einem erstellten Skript bearbeitet und der eigentliche Schervorgang aus den Zeitreihen extrahiert. Dieser Schritt bewirkte neben einer Reduktion der zu verarbeitenden Datenmenge auch eine Verbesserung der später mit dem KNN erzielten Vorhersagequalität, da nur die physikalisch relevanten Bereiche des aufgezeichneten Messsignals betrachtet wurden.

Abschließend erfolgte eine Transformation der aufgezeichneten Daten mit PCA (Principal Component Analysis)-Verfahren. PCA ist eine Methode zur Reduzierung eines Datensatzes und zur Extraktion von Features, welche die individuellen Unterschiede des Prozesses beschreiben [14]. Vorherige Untersuchungen hatten gezeigt, dass die Anwendung der PCA auf ein ähnliches Problem gute Ergebnisse lieferte [10]. In den hier vorgestellten Untersuchungen wurde die PCA mit den durch Schneidversuche bestimmten Datensatz durchgeführt, um einen reduzierten Datensatz auf der Basis von Features zu identifizieren, der die ursprünglichen Daten in einem niedrigdimensionalen Unterraum mit einem möglichst geringen Verlust an Informationen repräsentiert. Diese Dimensionsreduktion erfolgt durch eine Hauptachsentransformation. Die PCA wurde so durchgeführt, dass durch die ermittelten Features 95 % der Varianz des Ausgangsdatsatzes beschrieben wurden. Diese Bedingung konnte mit fünf Merkmalen erreicht werden, welche durch den PCA-Algorithmus

Tabelle. Untersuchte Hyperparameter und Parameterräume der Hyperparameteroptimierung.

Parameter	Parameterraum
Anzahl der versteckten Schichten	1 – 10
Neuronen pro versteckter Schicht	5 to 50 (Schrittweite 5)
Aktivierungsfunktion	Sigmoid, relu

bestimmt wurden. Nach Abschluss dieser Schritte zur Datenerfassung, -vorbereitung und -transformation lag ein Datensatz mit fünf durch die PCA bestimmten Eingangsgrößen und fünf Ausgabegrößen (R_m , $R_{p0.2}$, R_e , A_v , A_G , n) vor.

4 Modellbildung und -evaluation

Zur Modellierung des Regressionsproblems wurde ein künstliches neuronales Netz (KNN) eingesetzt. Dieses wurde ausgewählt, da KNN durch gezieltes Training beliebige, in der Datenstruktur verborgene Funktionen approximieren („lernen“) können [15, 16]. Vor allem Nichtlinearitäten und Abhängigkeiten zwischen den Eingangsparametern können diese Modelle gut abbilden. Die Auswahl angemessener Modellhyperparameter ist dabei von entscheidender Bedeutung, um Probleme wie Überanpassung oder Unteranpassung zu vermeiden und eine gute Generalisierungsfähigkeit in Bezug auf unbekannte Daten zu gewährleisten.

Hyperparameter haben einen entscheidenden Einfluss auf ML-Modelle und bestimmen neben der Struktur auch das Verhalten des Modells. Diese Parameter müssen vor dem Start des Trainingsprozesses festgelegt werden. Typische Hyperparameter sind etwa Anzahl der versteckten Schichten, Anzahl der Neuronen je versteckter Schicht und Art der verwendeten Aktivierungsfunktion. Im Gegensatz zu den Modellgewichten werden Hyperparameter nicht direkt aus den Trainingsdaten gelernt und müssen durch den Anwender oder durch einen Optimierungsalgorithmus festgelegt werden. In den Untersuchungen erfolgte die Optimierung der Hyperparameter des ML-Modells mit dem in Keras integrierten Optimierungsalgorithmus „Hyperband“ [17]. Hyperband trainiert

verschiedene Hyperparameterkonfigurationen für wenige Epochen und bricht schlechte Konfigurationen frühzeitig ab. Er fokussiert sich auf vielversprechendere Parameterkonfigurationen, um Ressourcen zu sparen und die Leistung zu verbessern. Optimierungsgrößen sind die Anzahl der versteckten Schichten, die Anzahl der Neuronen je versteckter Schicht und die Art der verwendeten Aktivierungsfunktion. Die **Tabelle** gibt eine Übersicht über die Parameter und die untersuchten Parameterräume.

Die durchgeführte Optimierung führte zu folgender Topologie des KNNs: Das KNN besteht aus einer Eingangsschicht mit fünf Neuronen, fünf versteckten Schichten mit 40, 40, 20, 30, 45 Neuronen und einer Ausgabeschicht mit fünf Neuronen zur Vorhersage der Werkstoffkennwerte R_m , $R_{p0.2}$, R_e , A_v , A_G , n .

Die Bewertung des KNNs erfolgte schließlich durch das Bestimmtheitsmaß R^2 , welches gemäß

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2}$$

aus den durch das Modell bestimmten Werten und den im Zugversuch experimentell ermittelten Werten der Testdaten gebildet wurde. Das Bestimmtheitsmaß wird aus den Messwerten y_i , dem empirischen Mittelwert \bar{y} und den durch das Modell prognostizierten Werten \hat{y}_i gebildet. [18]

5 Ergebnisse und Diskussion

Das Training des KNN wurde in 77 Epochen ausgeführt und durch ein Early-Stopping-Kriterium beendet. **Bild 3** zeigt eine Evaluation des erstellten Modells.

Für diese Evaluation wurden die 5% zurückgestellten Testdaten verwendet. Es werden die durch das KNN vorhergesagten mechanischen Werkstoffkennwerte, auf der Ordinate, verglichen mit den im Zugversuch gemessenen mechanischen Werkstoffkennwerten, auf der Abszisse. Die zusätzlich in Rot eingezeichnete Linie markiert die Übereinstimmung von Vorhersage zu im Versuch gemessenen Werten. Je geringer der Abstand eines Punktes zur roten Linie, desto genauer ist die Vorhersage. Liegt der Wert oberhalb der roten Linie, ist die Vorhersage des Modells zu hoch. Liegt der Wert unter der roten Linie, ist der vorhergesagte Wert zu gering. Die vorhergesagten Werte liegen zum Großteil

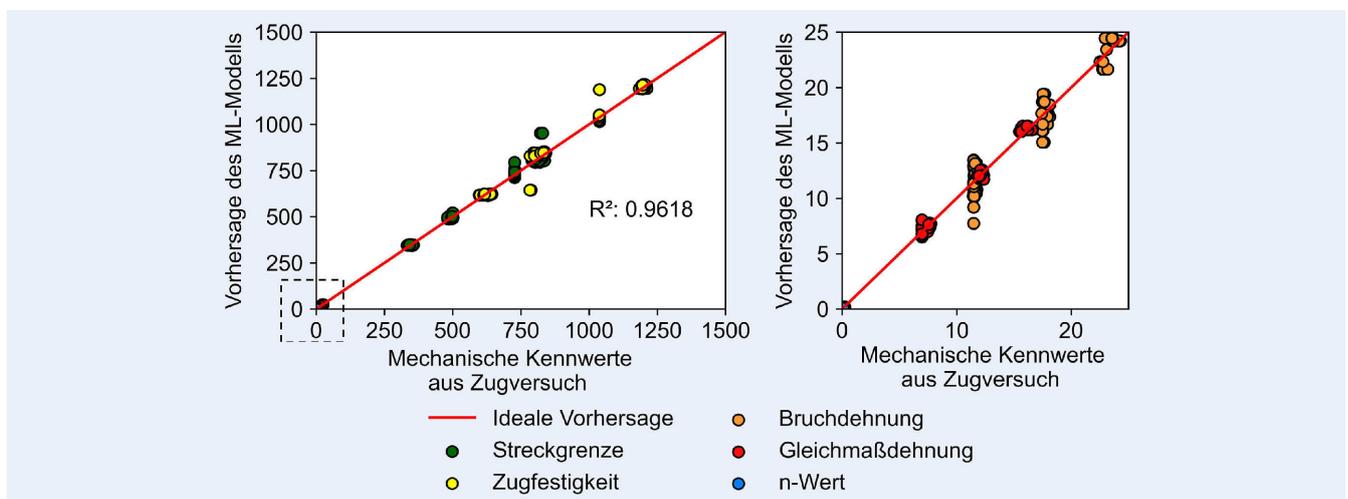


Bild 3. Vergleich zwischen den durch das ML (maschinelles Lernen)-Modell vorhergesagten Werten (Ordinate) und den Zielwerten aus Zugversuchen für den Testdatensatz (Abszisse) für die Größen R_m , $R_{p0.2}$, R_e , A_v , A_G , n -Wert. Grafik: IFU

auf der Linie der optimalen Vorhersage, lediglich einige Ausreißer weisen etwas größere Abweichungen auf. Diese gute Vorhersagegenauigkeit des erstellten KNN wird durch das im Bild 3 zusätzlich eingezeichnete, hohe Bestimmtheitsmaß von 0,9618 bestätigt. Das Ergebnis zeigt, dass die in Kapitel 1 formulierte Zielsetzung erreicht wurde. Die generelle Erkenntnis ist, dass eine Bestimmung von mechanischen Werkstoffkennwerten auf Basis von beim Scheren im offenen Schnitt gemessenen Dehnungsverläufen möglich ist.

6 Zusammenfassung und Ausblick

Blechteile werden üblicherweise in mehreren Umform- und Scherschneidvorgängen gefertigt. Die Qualität der hergestellten Bauteile hängt dabei maßgeblich von den mechanischen Eigenschaften des verwendeten Blechwerkstoffs ab. Schwankungen in den mechanischen Eigenschaften des Blechwerkstoffs, zum Beispiel aufgrund von Chargenschwankungen, sind Hauptursachen für Qualitätsmängel wie Versagen durch Riss, Formabweichungen oder Oberflächenfehler an Blechbauteilen. Diese Abweichungen der mechanischen Eigenschaften können sowohl in Bezug auf die Coillänge als auch auf die Coillbreite variieren.

Aufgrund der Tatsache, dass die bestehenden Methoden zur Materialcharakterisierung entweder nicht vollständig inline-fähig sind oder teure Messgeräte erfordern, wurde in den hier vorgestellten Untersuchungen eine neue, praxisorientiertere Methode zur Inline-Materialcharakterisierung entwickelt. Das Konzept dieser Methode basiert auf Analogien zwischen den während des Prozesses gemessenen Dehnungen in einer Abtrennstufe und den im Zugversuch gemessenen mechanischen Werkstoffkennwerten. Durch den Einsatz eines vortrainierten Neuronales Netzes, das die Beschreibung von nichtlinearen Zusammenhängen reproduzierbar macht, konnte eine Vorhersage der Materialkennwerte auf Basis der gemessenen Dehnungen im Obermesser der Abtrennstufe mit hoher Genauigkeit erzielt werden.

Um die in diesem Beitrag vorgestellten Forschungsarbeiten weiterzuführen, werden aktuell am IFU darauf aufbauende Untersuchungen durchgeführt. Neben der Übertragbarkeit der verwendeten Modelle auf andere Pressen und Schneidwerkzeuge soll in diesen Untersuchungen auch die Übertragbarkeit auf andere Materialklassen wie Kupfer oder Aluminium bewertet werden. Zudem soll der Einfluss des Verschleißes der Werkzeugteile auf die Vorhersagequalität der Modelle mittels Dauerlauftests untersucht werden. Weiterhin kann die vorgestellte Methode als Grundlage für eine Inline-Prozessüberwachung und gegebenenfalls als Sensor zur Messung von Eingangsgrößen für die Regelung von Umformprozessen eingesetzt werden.

Literatur

- [1] Lange, K. (Hrsg.): Umformtechnik Handbuch für Industrie und Wissenschaft. Band 3: Blechbearbeitung. Heidelberg: Springer-Verlag 1990
- [2] Souza, T. de; Rolfe, B. F.: Characterising material and process variation effects on springback robustness for a semi-cylindrical sheet metal forming process. *International Journal of Mechanical Sciences* 52 (2010) 12, pp. 1756–1766
- [3] Sturm, V.: Einfluss von Chargenschwankungen auf die Verarbeitungsgrenzen von Stahlwerkstoffen. Dissertation, Friedrich-Alexander-Universität Erlangen-Nürnberg, 2014
- [4] Maier, S. J.: Inline-Qualitätsprüfung im Presswerk durch intelligente Nachfolgewerkzeuge. Dissertation, Technische Universität München, 2017
- [5] Faaß, I.: Prozessregelung für die Fertigung von Karosserieteilen in Presswerken. Dissertation, Technische Universität München, 2009
- [6] Held, C.; Liewald, M.; Sindel, M.: Untersuchungen zum Einfluss werkstofflicher Schwankungen innerhalb eines Coils auf die Umformbarkeit. *wt Werkstatttechnik online* 99 (2009) 10, S. 732–739. Internet: www.werkstatttechnik.de. Düsseldorf: Springer-VDI-Verlag
- [7] Ružovič, M.: Die zerstörungsfreie Ermittlung von genauen Zugversuchsdaten mit dem Wirbelstromverfahren. Dissertation, Eidgenössische Technische Hochschule Zürich, 2004
- [8] Wiesenmayer, S.; Frey, P.; Lechner, M. et al.: Determination of the properties of semi-finished parts in blanking processes. *IOP Conference Series: Materials Science and Engineering* 967 (2020) 1, #12009
- [9] Schenek, A.; Görz, M.; Liewald, M. et al.: Data-Driven Derivation of Sheet Metal Properties Gained from Punching Forces Using an Artificial Neural Network. *Key Engineering Materials* 926 (2022), pp. 2174–2182
- [10] Görz, M.; Schenek, A.; Liewald, M. et al.: Evaluation of Feature Engineering Methods for the Prediction of Sheet Metal Properties from Punching Force Curves by an Artificial Neural Network. In: Zhang, M.; Peng, Z.; Li, B. et al. (Hrsg.): *Characterization of Minerals, Metals, and Materials 2023*. Cham: Springer Nature 2023, pp. 75–85
- [11] Molitor, D. A.; Kubik, C.; Knoll, M. et al.: Ableitung eines Vorgehensmodells zur systematischen Wissensgenerierung aus Sensordaten. *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 116 (2021) 5, S. 352–357
- [12] Kubik, C.; Molitor, D. A.; Becker, M. et al.: Knowledge Discovery in Engineering Applications Using Machine Learning Techniques. *Journal of Manufacturing Science and Engineering* 144 (2022) 9, #091003, doi.org/10.1115/1.4054158
- [13] HBM GmbH: Datenblatt – SLB700A/06VA. Dehnungsaufnehmer. Internet: www.hbm.com/fileadmin/mediapool/hbmdoc/technical/b3254.pdf. Zugriff am 25.09.2023
- [14] Jolliffe, I. T.: *Principal Component Analysis*. New York: Springer-Verlag 2002
- [15] Haykin, S.: *Neural networks. A comprehensive foundation*. Delhi: Pearson Education 1999
- [16] Hornik, K.: Approximation capabilities of multilayer feedforward networks. *Neural Networks* 4 (1991) 2, pp. 251–257
- [17] Li, L.; Jamieson, K.; DeSalvo, G. et al.: Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization. *Journal of Machine Learning Research* (2018) 18, pp. 1–52
- [18] Fahrmeir, L.; Heumann, C.; Künstler, R. et al.: *Statistik. Der Weg zur Datenanalyse*. Heidelberg: Springer Spektrum 2016



Marcel Görz, M.Sc.

Foto: IFU

Adrian Schenek, M.Sc.

Prof. Dr.-Ing. **Mathias Liewald** MBA

Dr.-Ing. **Kim Rouven Riedmüller**

Universität Stuttgart, Institut für Umformtechnik (IFU)

Holzgartenstr. 17, 70174 Stuttgart

Tel. +49 711 / 685-84546

marcel.goerz@ifu.uni-stuttgart.de

www.ifu.uni-stuttgart.de

LIZENZ



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