

KI-gestützte Prozessoptimierung in der Massivumformung

Claudia Glaubitz,
Julian Raible,
Helena Monke,
Marcel Rothgänger,
Julius Peddinghaus und
Kai Brunotte*

Das Teilprojekt „Transparente KI-gestützte Prozessmodellierung im Gesenkschmieden“ des Schwerpunktprogramms (SPP) 2422 der Deutschen Forschungsgesellschaft (DFG) strebt die Optimierung des Gesenkschmiedens durch den Einsatz künstlicher Intelligenz (KI) an. Bisher werden Materialaufmaße genutzt, um Prozessschwankungen zu kompensieren. Erklärbare KI-Modelle ermöglichen die Analyse der Wirkzusammenhänge zwischen Prozessparametern auf Geometrieabweichungen und sollen zukünftig zur Optimierung der Prozess- und Werkzeuggestaltung genutzt werden. Dadurch können Material- und Energiebedarf reduziert werden, was zur Steigerung der Nachhaltigkeit in der Massivumformung beiträgt.

Einführung in das Gesenkschmieden und seine Prozessparameter

Beim Gesenkschmieden wird ein auf Umformtemperatur erhitztes Halbzeug durch das Schließen von Ober- und Untergesenk in eine gewünschte Form gebracht. Während des Schließvorgangs wird überschüssiges Material kontrolliert durch den sich verengenden Gratspalt in den Gratbahnbereich der Gesenkform geleitet. Die Verengung des Gratspals sowie die begrenzte Kapazität des Gratbahnbereichs erzeugen einen Widerstand gegen

das Abfließen des Materials, wodurch ein definierter Gegendruck aufgebaut wird. Der Gegendruck sorgt dafür, dass auch komplexe Bereiche der Gesenkform vollständig ausgefüllt werden, da das Material aufgrund des begrenzten Abflusses in die Vertiefungen zurückgedrückt wird [1, 6]. Dieser Effekt ist entscheidend für die Vermeidung von Formfüllungsfehlern, erfordert jedoch eine genaue Dosierung des überschüssigen Materials, da zu viel oder zu wenig Gratmaterial den Prozess negativ beeinflussen kann. Das Grativolumen wird durch die Gratspaltgeometrie und die dort wirkenden Reibungsverhält-

nisse beeinflusst. Seine Entstehungsbedingungen bestimmen maßgeblich den Materialfluss im Gesenk und wirken sich erheblich auf die Energie- und Materialeffizienz eines Schmiedeprozesses aus. Das überschüssige Material wird vor der Umformung ebenfalls erwärmt und muss nach der Umformung entfernt werden, was zusätzlichen Arbeits- und Energieaufwand verursacht. Zwar hat sich die Gratbildung als verlässliche Methode zur Sicherstellung der Formfüllung bei serienschmiedetypischen Prozessschwankungen bewährt, jedoch sollte das Grativolumen aus Effizienzgründen so klein wie möglich gehalten werden [2].

Die Reduzierung von Sicherheitszugaben in Schmiedeverfahren hängt entscheidend von den Möglichkeiten und der Qualität der Prozessüberwachung und -regelung ab. In Serienprozessen stellt insbesondere der zeitabhängige Wärmeeintrag eine besondere Herausforderung dar, da die thermische Trägheit der Materialien sowie die variierenden Wärmeleitkoeffizienten zu nichtlinearen und komplexen thermischen Verhältnissen führen. Diese Faktoren erschweren eine genaue Vorhersage und Steuerung der Temperaturverteilung und deren Einfluss auf den Materialfluss. Die

* Korrespondenzautorin

Dipl.-Ing. Claudia Glaubitz; Institut für Umformtechnik und Umformmaschinen (IFUM), Leibniz Universität Hannover; An der Universität 2, 30823 Hannover; Tel.: +49 (0) 174 762 0360, E-Mail: glaubitz@ifum.uni-hannover.de

Weitere Autor:innen

Dipl.-Ing. Julian Raible; Institut für Industrielle Fertigung und Fabrikbetrieb, Universität Stuttgart
Helena Monke, M. Sc.; Institut für Industrielle Fertigung und Fabrikbetrieb, Universität Stuttgart
Marcel Rothgänger, M. Sc.; IFUM an der Leibniz Universität Hannover
Julius Peddinghaus, M. Sc.; IFUM an der Leibniz Universität Hannover
Dr.-Ing. Kai Brunotte; IFUM an der Leibniz Universität Hannover

Hinweis

Bei diesem Beitrag handelt es sich um einen von den Advisory-Board-Mitgliedern des ZWF-Sonderheftes wissenschaftlich begutachteten Fachaufsatz (Peer-Review).

Zeit	Zähler	Einlege- pos. X in mm	Radius in mm	Masse in g	T _{Ofen} in °C	T _{Gesenk} in °C	F _{max} in kN	Gratbahn- radius in mm	Gratdicke in mm	Datei
14:10:00	39361	0,72	15	221	975	1216	1587	26,59	2,85	...87.me3dpc
14:11:00	39362	0,5	15,1	221	1019	1245	1516	26,75	2,64	...63.me3dpc
14:11:00	39363	1,29	15,2	220	1064	1275	1514	27,13	2,75	...10.me3dpc
14:11:00	39364	0,545	15,1	221	1116	1303	1410	27,73	2,53	...03.me3dpc
14:11:00	39365	1,09	15,1	220	1166	1329	1391	28,07	2,48	...32.me3dpc
...	...	...	...	...	...	...	...	...	...	...

*Tabelle 1. Exemplari-
scher, verkürzter Auszug
aus der Prozessdaten-
bank des Demonstrator-
prozesses*

hohen Werkstücktemperaturen und schmiedebedingten Verschmutzungen beispielsweise durch den Schmierstoff erschweren zudem die präzise Datenerfassung im laufenden Betrieb. Qualitätsüberprüfungen erfolgen deshalb bisher stichprobenartig und zumeist taktil, womit die erfassten Datenmengen nur lokal und sehr begrenzt sind [3].

Der Zusammenhang zwischen der Gratbildung und der Formfüllung eines Gesenkschmiedeteils lässt sich auf die Gesetzmäßigkeit der Volumenkonstanz zurückführen. Allerdings wird dieser grundlegende Prozess nicht ausschließlich durch die komplexen, lokalen Temperaturverteilungen beeinflusst, sondern auch durch die Wechselwirkungen zwischen der aufgebrachten Umformkraft und den Reibungsverhältnissen an den Kontaktflächen im Gesenk [1]. Diese und weitere Faktoren, wie z.B. auch ein Stößelversatz der Umformmaschine, wirken sich auf den Materialfluss aus und bestimmen sowohl die Qualität der Formfüllung als auch das Volumen und die Geometrie des entstehenden Grats [4].

Die Erfassung bestimmter Prozessgrößen gestaltet sich jedoch als äußerst schwierig. So sind beispielsweise die lokalen Reibungsverhältnisse im Gesenk im Umformprozess nicht direkt messbar. Diese fehlende Verfügbarkeit relevanter Prozessdaten stellt eine Herausforderung für die genaue Modellierung und Optimierung des Schmiedeprozesses dar. Die komplexen Wechselwirkungen zwischen den messbaren Einflussgrößen können zudem in ihrem Umfang und ihrem zeitlichen Verlauf von einem Menschen nicht mehr verarbeitet werden. Hier kommen maschinelle Lernsysteme zum Einsatz, die durch die Erfassung und Analyse großer Datenmengen, wie etwa Kraftverläufe, Temperaturverteilungen und geometri-

sche Merkmale, Muster erkennen und Korrelationen aufdecken können [5]. Diese KI-gestützten Systeme ermöglichen eine präzisere Prozesssteuerung und bieten durch kontinuierliches Lernen das Potenzial, bisher unbekannte Zusammenhänge zwischen Prozessparametern und Formabweichungen zu identifizieren [7].

In-line Datenerfassung und Modellerstellung

Im Rahmen des Teilprojektes im DFG-Schwerpunktprogramm 2422 wurden verschiedene Sensoren zur In-Line-Datenerfassung in einen vollautomatisierten Demonstratorschmiedeprozess an verschiedenen Messpositionen integriert. Hierzu zählen unter anderem eine Wägezelle zur Messung des Halbzeuggewichts, Kraftmesskörper an den Werkzeugaufbauten, ein Linienlasersystem zur Erfassung der Einlegeposition des Halbzeuges, ein Pyrometer am Ofenausgang sowie im Pressenraum und ein Linienlasersensor zur dreidimensionalen Bildgebung des geschmiedeten noch warmen Werkstücks am Prozessausgang. Diese Sensoren liefern kontinuierlich Daten, die mit maschinellen Lernalgorithmen ausgewertet werden. Das Ziel ist es, ein Modell des Schmiedeprozesses zu erstellen, das Zusammenhänge zwischen Prozessgrößen und Qualitätsmerkmalen abbildet. Dieses Modell mit Black-Box-Charakter kann Vorhersagen treffen, ohne dass die zugrunde liegenden Kausalzusammenhänge zunächst ersichtlich sind.

Datenaufnahme im Demonstratorschmiedeprozess

Zur In-line-Überwachung der Gratbildung am Schmiedestück wird ein Linienlasermessverfahren mit dem Micro-Epsilon

LLT 010-100/BL-Sensor und der Software *3DInspect* angewendet. Schmiedewarme Bauteile können mit dem Messverfahren berührungslos erfasst und deren Geometrie in-line anhand von Schwellenwerten bzw. OK-/nOk-Signalen automatisiert beurteilt werden.

Zur Veranschaulichung der geplanten Dateninfrastruktur im Projekt wurden versuchsweise 34 Bauteile geschmiedet. Die zylindrischen Halbzeuge (Höhe 40 mm, Durchmesser 30 mm) wurden induktiv erwärmt und ihre Temperatur T_{Ofen} wurde am Ofenausgang mit einem Pyrometer erfasst. Ein Roboter greift nur Halbzeuge, die sich im festgelegten Temperaturbereich befinden, und stellt sie auf der Wägezellenplattform ab. Dieser Temperaturbereich kann durch Einschwingphasen der Induktionsanlage oder dem kumulativen Wärmeeintrag über- oder unterschritten werden und wird dann entsprechend nachgeregelt. Nach Abwarten der Einschwingzeit des Halbzeuges auf der Wägezellenplattform und dem Abgreifen des eingependelten Massewertes greift der Roboter erneut und stellt das Halbzeug im Untergesenk im Pressenraum ab. Mit den Messdaten eines Linienlasers im Pressenraum wird der Radius des zylindrischen Halbzeuges erfasst und die exakte Einlegeposition in x- und y-Richtung dokumentiert. Während der Umformung wird die maximale Pressenkraft F_{max} über Dehnungsmessstreifen an den Werkzeugaufbauten erfasst. Mit einem blauen Linienlaser wird am Prozessausgang über eine sensorisch initiierte Relativbewegung zwischen Bauteil und Sensorkopf eine dreidimensionale Punktwolke erstellt, die sowohl in-line als auch im Nachhinein ausgewertet werden kann. In Tabelle 1 ist die erstellte Prozessdatenbank für fünf von insgesamt 34 gemessenen Bauteilen exemplarisch dargestellt.




Bild 1. 3D-Linienlaserscan bei schmiedewarmer Bauteiltemperatur, Punktwolke des zur Umformrichtung rotationssymmetrischen Demonstrators, Detektion der Gratbahnbildung über Kreispassung an Kantenschwellwert, Ausgabe des Gratbahnradius (roter Pfeil) an Prozessdatenbank

Der Demonstrator liegt rotationssymmetrisch zur Umformrichtung und bildet eine nahezu kreisrunde, teilweise leicht ovalisierte Gratbahn aus. Die Visualisierung einer Laserpunktwolke ist in Bild 1 dargestellt. Mit der Software 3DInspect lässt sich der Radius dieser Kreispassung über die Angabe eines Kantenschwellwertes automatisiert detektieren und an die

Datenbank übergeben. Die Gratdicke wird zusätzlich im Anschluss durch eine weitere seitliche, bisher noch nicht vollständig automatisierte Messung erfasst. Die Analyse der gewonnenen Prozessdaten kann bei kleinen Datensätzen mithilfe klassischer Statistikprogramme ohne den Einsatz von künstlicher Intelligenz durchgeführt werden. Zu den typischen Methoden

gehören deskriptive Statistiken, Korrelations- und Regressionsanalysen sowie Varianzanalysen. Diese Ansätze sind hilfreich, um lineare Zusammenhänge, wie z. B. die Korrelationen (Bild 2), zu identifizieren. Bei höheren Einlegetemperaturen führt eine geringere Fließspannung des Werkstoffs zu einer großflächigeren Gratausbildung (Bild 2a). Eine Gegenüberstellung mit den maximalen Umformkräften zeigt wiederum eine negative Korrelation zur Gratbahnfläche (Bild 2b). Die benötigte Kraft zur Umformung bis zum Pressenschlag wird durch die verminderte Fließspannung bzw. die erhöhte Einlegetemperatur reduziert.

Bild 2c ist eine weniger deutliche Relation zwischen den Kraftspitzen im Umformprozess und der resultierenden Gratdicke zu entnehmen. Zu Prozessbeginn treten höhere Umformkräfte auf und an den ersten Werkstücken (im Bild rot markiert) wird ein dickerer Grat gebildet als an den Werkstücken im weiteren Prozessverlauf. Der Zusammenhang ist zu Prozessbeginn noch linear, wird aber im weiteren Prozessverlauf komple-




Bild 2. Korrelationen zwischen Einlegetemperatur (T_{offen}) (a) und max. Umformkraft (b) zum Gratbahnradius und Gratdicke (c) mit Markierung des Prozessbeginns rot (r: Pearson-Korrelationskoeffizient, KI: Konfidenzintervall)

xer und verliert seine Linearität. Das resultierende Gratvolumen aus dem Gratbahnradius und der Gratdicke wird im Prozessverlauf entsprechend größer und steigt um etwa 4 Prozent des Halbzeuggewichtes an. Aufgrund der Volumenkonstanz kann das Material, welches in den Grat gedrückt wurde, nicht mehr in der Gesenkgravur vorhanden sein. Bei zu engen Prozessfenstern könnte dies zu Unterfüllungen am Werkstück führen. Maschinelle Lernverfahren erscheinen hier vielversprechend, um den mehrdimensionalen Zusammenhang zwischen Tempe-

ratur, Umformkraft und Gratbildung besser zu verstehen. Zudem können weitere Prozessgrößen einbezogen werden, deren Einfluss mit klassischen Statistikmethoden nicht identifiziert werden kann.

Prozessanalyse und der Einsatz von KI beim Demonstratorschmiedeprozess

Klassische statistische Ansätze stoßen an ihre Grenze, wenn die Daten komplexere, nichtlineare Beziehungen oder multidimensionale Abhängigkeiten aufweisen. Ein weiterer Nachteil ist, dass diese Methoden oft von bestimmten Annahmen, wie der Normalverteilung der Daten ausgehen, was in realen Prozessen nicht immer gegeben ist. Wenn mehrere Variablen miteinander interagieren, wird die Anwendung und Interpretation der Ergebnisse mit herkömmlichen Methoden zunehmend schwieriger. KI-gestützte Vorhersagemodelle können verwendet werden, um zukünftige Prozesszustände, wie die maximale Pressenkraft, auf Basis der Eingangsparameter vorherzusagen. Darüber hinaus können Verfahren wie

Zielgröße	RMSE der Kreuzvalidierung (Mittelwert für 10 Splits) mit Normierung	RMSE der Kreuzvalidierung (Standardabweichung für 10 Splits) mit Normierung
Gratbahnradius	0,23 mm/6,4%	0,07 mm/1,9%
Gratdicke	0,13 mm/17,1%	0,10mm / 13,1%

Tabelle 2. RMSE des Lasso-Verfahrens

Clustering und Anomalieerkennung dazu beitragen, untypische Prozessparameter oder Qualitätsabweichungen automatisch zu erkennen und so die Prozessqualität zu verbessern.

Im Rahmen des Demonstratorschmiedeprozesses wird aufgrund der geringen Datenbasis die Lasso-Regression (Least Absolute Shrinkage and Selection Operator), ein einfaches lineares KI-Modell, eingesetzt. Dieses Verfahren basiert auf linearer Regression und nutzt einen Strafterm, um die Anzahl der Koeffizienten zu minimieren. Dadurch wird die Komplexität des Modells reduziert, was unter anderem die Interpretierbarkeit verbessert. Das Modell wird gemäß des Kreuzvalidierungsprinzips trainiert und getestet. Die Modellabweichung wird mittels des Root Mean Squared Errors

(RMSE) über 10 Splits hinsichtlich der Kreuzvalidierung gemittelt und mit der Standardabweichung angegeben. Zusätzlich werden die Fehler auf den Wertebereich der Zielgröße normiert und prozentual angegeben. Die Ergebnisse der Fits bezüglich der beiden Zielgrößen Gratbahnradius und Gratdicke finden sich in Tabelle 2. Es können demnach Qualitätsmerkmale bereits mit moderaten Genauigkeiten durch lineare Modelle vorhergesagt werden. Die identifizierten Parameter der Lasso-Regression, die hier nicht aufgeführt werden, spiegeln die bereits in Bild 2a und 2b optisch erkennbaren Korrelationen (positive Korrelation für die Einlegetemperatur und negative Korrelation für die maximale Umformkraft in Bezug auf den Gratbahnradius) wider.

Eine alternative Möglichkeit bietet die Betrachtung als Klassifikationsproblem. Hierzu eignet sich ein Entscheidungsbaum. Dieser Algorithmus segmentiert mithilfe von Wenn-Dann-Regeln Datenpunkte, sodass in den Blattknoten, die das Ende einer Verkettung von Entscheidungen repräsentieren, reine Klassen vorliegen. Hierzu können die Zielgrößen äquidistant diskretisiert und in Klassen eingeteilt werden. Der Klassifikator des Entscheidungsbaumes wird ebenfalls nach dem Kreuzvalidierungsprinzip trainiert und evaluiert. Hinsichtlich der Zielgröße des Gratbahnradius liegt der Anteil der korrekt klassifizierten Datenpunkte für Testdaten bei 79,04 Prozent mit einer Standardabweichung von 8,34 Prozent. Exemplarisch ist ein Entscheidungsbaum in Bezug auf Trainingsdaten in Bild 3 zur Klassifikation des Gratbahnradius dargestellt. An diesem Modell können bereits einfache Zusammenhänge zwischen Prozessgrößen und Qualitätsmerkmalen abgelesen und interpretiert werden. Bei erfüllten Bedingungen des jeweiligen Knotens wird im linken Ast fortgefahren, ansonsten im rechten Ast. Diese beiden Modelle zeigen, dass bereits durch den Einsatz einfacher, weniger komplexer KI-




Bild 3. Entscheidungsbaum zur Klassifikation der Größe des Gratbahnradius. „Value“ zeigt die Verteilung der Datenpunkte auf die Kategorien des Gratbahnradius (siehe Legende), „Class“ gibt die am häufigsten vorkommende Kategorie im Knoten an und stellt die Vorhersage des Entscheidungsbaums dar. Die Farbe des Kastens entspricht dieser Kategorie. „Samples“ zeigt den Anteil der Datenpunkte, die in diesem Zweig des Entscheidungsbaums liegen. T_{Gesenk} bezeichnet die Temperaturmessdaten eines zusätzlichen Pyrometers im Pressenraum, die nicht auf Plausibilität geprüft wurden und hier nur zur Veranschaulichung dienen

Algorithmen Muster in den Prozessdaten identifiziert werden können. So wird durch das Modell beispielsweise die Korrelation zwischen steigender Einlegetemperatur und vergrößerter Gratbildung ersichtlich, da eine geringere Fließspannung im Material zu einem erhöhten Materialfluss führt.

Zudem werden Zusammenhänge zwischen der maximalen Umformkraft und der Geometrie des entstehenden Grats sichtbar. Dies ermöglicht die zuverlässige Prädiktion von Qualitätsmerkmalen oder auch die Veranschaulichung gefundener Zusammenhänge in Form von Wenn-Dann-Regeln. Ähnliche Experimente mit Entscheidungsbäumen, die zur Klassifikation der Gratdicke trainiert wurden, konnten Genauigkeiten von ca. 40 Prozent erreichen, was sich mit den Ergebnissen der Lasso-Regression deckt, für die ebenfalls höhere Ungenauigkeiten in Bezug auf die Gratdicke auftraten. Dies unterstreicht die Notwendigkeit zum Einsatz komplexerer Modelle, wie neuronaler Netze, die in der Lage sind, vielseitigere Zusammenhänge zu modellieren, womit sich die Zielgrößen genauer präzisieren lassen. Dies lässt sich allerdings erst mit einer größeren Datenbasis im weiteren Projektverlauf umsetzen. Derartige Modelle erreichen eine höhere Genauigkeit und Zuverlässigkeit und können zudem noch in einen Entscheidungsbaum überführt werden, wodurch ähnlich zu Bild 1 Zusammenhänge visualisiert werden können. Die höhere Genauigkeit des neuronalen Netzes bleibt dabei erhalten, sodass man hohe Genauigkeit und Interpretierbarkeit zugleich erreichen kann. Präzise Vorhersagen können nachvollziehbar dargelegt werden. Die Interpretierbarkeit des Modells sorgt dafür, dass die Wirkzusammenhänge zwischen verschiedenen Parametern und den daraus resultierenden Qualitätsmerkmalen wie Bauteilgeometrie und Gratbildung transparent dargestellt werden. Dadurch können Prozessverantwortliche genau nachvollziehen, welche Faktoren die Modellentscheidungen beeinflusst haben, und diese Erkenntnisse gezielt für Prozessverbesserungen nutzen.

■ Zusammenfassung und Ausblick

Die Integration von KI in die Prozessoptimierung der Massivumformung bietet

Potenziale zur Effizienzsteigerung und Ressourcenschonung. Durch den Einsatz von erklärbaren KI-Modellen lassen sich komplexe Zusammenhänge zwischen Prozessparametern analysieren und für die Optimierung der Prozess- und Werkzeuggestaltung nutzen. Die kontinuierliche Datenerfassung durch Sensorik und deren Auswertung mit maschinellen Lernverfahren ermöglichen eine präzise Prozessüberwachung und vorausschauende Steuerung. Vorhersagen zu Prozesszuständen und die automatische Erkennung von Anomalien tragen zur Steigerung der Produktionsqualität bei und senken gleichzeitig den Material- und Energieverbrauch.

Die Ergebnisse dieser Untersuchung, die aus einer begrenzten Datenmenge gewonnen wurden, dienen vorrangig der Veranschaulichung der Potenziale, die KI für die Prozessoptimierung im Schmieden bietet. Die Prognosegüte des Entscheidungsbaumes beträgt 79 Prozent und demonstriert die Fähigkeit der KI, Wechselwirkungen zwischen geometrischen Merkmalen und Prozessparametern vorherzusagen. Diese Genauigkeit ist jedoch angesichts der geringen Datenbasis als moderat einzuschätzen und deutet darauf hin, dass die Prognosegenauigkeit durch eine umfassendere Datenbasis weiter gesteigert werden könnte.

Die Analyse zeigt jedoch, dass das KI-Modell bereits mit dieser eingeschränkten Datenbasis in der Lage ist, Muster zwischen wesentlichen Prozessparametern, wie der Einlegetemperatur und Umformkraft, sowie der resultierenden Gratbildung zu erkennen. Dabei stellt die zeitliche Abhängigkeit der thermischen Belastung im Schmiedeprozess eine besondere Herausforderung dar. Der kumulative Wärmeeintrag verringert die Fließspannung im Material zunehmend und verstärkt die Gratbildung im Prozessverlauf. Eine präzise Steuerung der Einlegetemperatur und eine Anpassung an die thermische Belastung während der Produktion hoher Stückzahlen sind daher wesentlich, um eine gleichmäßige Prozessqualität zu sichern und Materialverluste und Formfüllungsfehler durch übermäßige Gratbildung zu vermeiden.

Mithilfe der KI-gestützten Analyse kann die zeitliche Dimension der Wechselwirkungen analysiert werden. Der

Einsatz von neuronalen Netzen, wie Fully Connected Neural Networks (FCNNs), kann dabei in weiteren Untersuchungen eine leistungsstärkere Möglichkeit bieten die nichtlinearen Zusammenhänge im Schmiedeprozess zu modellieren als die hier verwendeten Algorithmen. Zeitabhängige Zusammenhänge zwischen den Prozessparametern wie Kraft, Temperatur und Gratbildung können durch Recurrent Neural Networks (RNNs) und Temporal Convolutional Networks (TCNs) erfasst werden. In einem nächsten Schritt kann ein White-Box-Modell erstellt werden, das eine erklärbare Darstellung der Prozesszusammenhänge bietet. Ein Beispiel hierfür ist die Transformation eines neuronalen Netzes in einen Entscheidungsbaum, der die wichtigsten Einflussgrößen, wie Umformkraft, Temperatur und Gratabhänge, in Form von Wenn-Dann-Regeln nachvollziehbar visualisiert.

Im Rahmen des Teilprojekts „Transparente KI-gestützte Prozessmodellierung im Gesenkschmieden“ des DFG SPP 2422 werden diese erklärbare KI-Modelle entwickelt und zunächst zur Optimierung der Vorformgebung in einem zweistufigen Schmiedeprozess eingesetzt. Hierzu erfolgt ein schrittweises Modelltraining durch die Aufnahme von Referenzdatensätzen, die den Standardprozess ohne spezifische Anpassungen abbilden und eine zuverlässige Basis für die Analyse bieten. Zur effizienten Verwaltung der großen Datenmengen, die im Verlauf der Schmiedeprozesse erfasst werden, wird InfluxDB, eine auf Zeitreihen spezialisierte Datenbank, genutzt. Diese ermöglicht die Speicherung und Analyse der zeitabhängigen Prozessdaten wie Temperatur- und Kraftverläufe in Echtzeit [8]. Im Anschluss daran wird die Vorformgeometrie sowohl simulativ als auch experimentell gezielt variiert oder einzelne Einflussgrößen werden systematisch angepasst. Diese methodische Variation liefert Datensätze, die eine differenzierte Analyse der Auswirkungen jeder Einflussgröße auf die Prozess- und Bauteilqualität ermöglichen. Durch den Vergleich der variierten Datensätze mit den Referenzdaten kann das Modell lernen, wie spezifische Veränderungen die Geometrie und Prozessparameter beeinflussen. Diese Datenbasis erlaubt es den KI-Modellen, Korrelationen zwischen den

Einflussfaktoren und den daraus resultierenden geometrischen Merkmalen zu erfassen und auf dieser Grundlage gezielte Optimierungsvorschläge zu generieren. Aufbauend auf diesen Erkenntnissen sollen die entwickelten KI-Modelle zukünftig weiter hinsichtlich der Prognosegüte sowie der Robustheit und Qualität der Datenaufnahme verfeinert und anschließend für die Anwendung in umfangreicheren Serienschmiederversuchen validiert werden.

Literatur

1. Rath, M. G.; Jakhade, N. A.: An Overview of Forging Processes with their Defects. *International Journal of Scientific and Research Publications* 4 (2014) 6, S. 1–6 (<http://www.ijsrp.org/research-paper-0614.php?rp=P302759> [Abgerufen am 10.02.2025])
2. Fereshteh-Saniee, F.; Hosseini, A. H.: The Effects of Flash Allowance and Bar Size on Forming Load and Metal Flow in Closed Die Forging. *Journal of Materials Processing Technology* 177(2006) 1–3, S. 261–265 DOI:10.1016/j.jmatprotec.2006.04.046
3. Differentiating between Tactile and Optical Measurement Technology for Dimensional Inspection. *metrology.news* (<https://metrology.news/differentiating-between-tactile-and-optical-measurement-technology-for-dimensional-inspection> [Abgerufen am 10.02.2025])
4. Tomov, B.; Radev, R.; Gagov, V.: Influence of Flash Design upon Process Parameters of Hot Die Forging. *Journal of Materials Processing Technology* 157 (2004) 1–2, S. 620–623 DOI:10.1016/j.jmatprotec.2004.07.124
5. Azamfirei, V.; Psarommatas, F.; Lagrosen, Y.: Application of Automation for In-line Quality Inspection, a Zero-defect Manufacturing Approach. *Journal of Manufacturing Systems* 67 (2023) 9, S. 1–22 DOI:10.1016/j.jmsy.2022.12.010
6. Mirahmadi, S. J.; Hamed, M.: Flash Gap Optimization in Precision Blade Forging. *International Journal of Mechanical Engineering and Robotics Research* 6 (2017) 3, S. 200–205 DOI:10.18178/ijmerr.6.3.200-205
7. Blake, R. W.; Mathew, R.; George, A.; apakostas, N.: Impact of Artificial Intelligence on Engineering: Past, Present and Future. *Procedia CIRP* 104 (2021), S. 1728–1733 DOI:10.1016/j.procir.2021.11.291
8. Zhu, X.; Nie, X.; Liu, J.: Time Series Database Optimization Based on InfluxDB. In: *International Conference on Power, Electrical Engineering, Electronics and Control*, PEEEC 2023, S. 879–885 DOI:10.1109/PEEEEC60561.2023.00172

Die Autor:innen dieses Beitrags

Dipl.-Ing. Claudia Glaubitz, geb. 1988, studierte Maschinenbau mit dem Schwerpunkt Energietechnik an der Leibniz Universität Hannover. Seit 2023 ist sie wissenschaftliche Mitarbeiterin im Bereich der Massivumformung am Institut für Umformtechnik und Umformmaschinen der Leibniz Universität Hannover. Dort liegt ihr Forschungsschwerpunkt in der datengetriebenen Prozessmodellierung.

Dipl.-Ing. Julian Raible, geb. 1992, studierte Maschinenbau mit den Schwerpunkten Grundlagen des Maschinenbaus und Mechatronik an der Technischen Universität Kaiserslautern. Seit 2021 ist er wissenschaftlicher Mitarbeiter am Institut für Industrielle Fertigung und Fabrikbetrieb der Universität Stuttgart im Bereich kognitive Produktionssysteme und am Fraunhofer-Institut für Produktionstechnik und Automatisierung im Bereich künstliche Intelligenz und Maschinelles Sehen.

Helena Monke, M.Sc., geb. 1999, studierte im Bachelor Geophysik mit Schwerpunkt Fluid-dynamik und im Bachelor und Master Physik mit Schwerpunkten Nichtlineare Physik und Materialphysik an der Universität Münster. Seit 2023 ist sie wissenschaftliche Mitarbeiterin am Institut für Industrielle Fertigung und Fabrikbetrieb der Universität Stuttgart im Bereich kognitive Produktionssysteme und am Fraunhofer-Institut für Produktionstechnik und Automatisierung im Bereich zuverlässige KI-Systeme.

Marcel Rothgänger, M.Sc., geb. 1989, leitet den Forschungsbereich „Skalierung in der Umformtechnik“ am Institut für Umformmaschinen und Umformtechnik. Sein Forschungsschwerpunkt ist die Optimierung von Umformprozessen durch Automatisierung und Digitalisierung mittels prozessübergreifender Datenerfassung und -analyse.

Julius Peddinghaus, M.Sc., geb. 1994, ist wissenschaftlicher Mitarbeiter und Bereichsleiter der Massivumformung im Institut für Umformmaschinen und Umformtechnik. Sein Forschungsschwerpunkt liegt in der Tribologie beim Gesenkschmieden sowie in der Entwicklung von Warmmassivumformprozessen.

Dr.-Ing. Kai Brunotte, geb. 1985, studierte Maschinenbau an der Leibniz Universität Hannover und begann 2013 als wissenschaftlicher Mitarbeiter am Institut für Umformtechnik

und Umformmaschinen, das er seit 2017 als Oberingenieur leitet. Er promovierte im Juli 2021 mit seiner Dissertation „Beitrag zur Steigerung der Standmenge von Werkzeugen der Warmmassivumformung durch den Einsatz lokaler belastungsangepasster Verschleißschutzbehandlungen“.

Abstract

AI-Supported Process Optimization in Bulk Metal Forming. The subproject “Transparent AI-Based Process Modelling in Die Forging” of the Priority Program (SPP) 2422 of the German Research Foundation (DFG) aims to optimize die forging through the use of artificial intelligence (AI). Currently, material allowances are used to compensate for process fluctuations. Explainable AI models enable the analysis of the interactions between process parameters and geometric deviations and are intended to be used in the future to optimize process and tool design. This can reduce material and energy requirements, contributing increasing sustainability in bulk metal forming.

Förderhinweis

Diese Arbeit wurde im Rahmen des Schwerpunktprogramms 2422 zur „Datengetriebenen Prozessmodellierung in der Umformtechnik“ durchgeführt, das seit 2023 von der Deutschen Forschungsgemeinschaft (DFG) gefördert wird.

Schlüsselwörter

Gesenkschmieden, Künstliche Intelligenz (KI), Parameterkorrelation, In-line-Optimierungspotenzial

Keywords

Die Forging, Artificial Intelligence (AI), Parameter Correlation, In-line Optimization Potential

Bibliography

DOI:10.1515/zwf-2024-0124
ZWF 120 (2025) Special Issue; page 257 – 262
Open Access. © 2025 bei den Autoren, publiziert von De Gruyter. 
Dieses Werk ist lizenziert unter der Creative Commons Namensnennung 4.0 International Lizenz.
ISSN 0947-0085 · e-ISSN 2511-0896