Data Mining für die Anwendung von künstlicher Intelligenz beim Gesenkschmieden

Bild: 1095727662 ©eriksvoboda, www.stock.adobe.com

Künstliche Intelligenz (KI) und maschinelles Lernen (ML) stellt für das Gesenkschmieden einen vielversprechenden Ansatz dar, um den aktuellen Herausforderungen im internationalen Wettbewerb zu begegnen. Die Grundlage dafür bildet das Data Mining, bei dem Daten systematisch erfasst werden, um immer leistungsfähiger werdende KI- und ML-Modelle anzuwenden. Dieser Beitrag stellt die Arbeiten am Institut für Umformtechnik und Umformmaschinen (IFUM) in der Befähigung von Schmiedeprozessen zur Implementierung von ML-Methoden vor.

Künstliche Intelligenz (KI) und maschinelles Lernen (ML) stellt für das Gesenkschmieden einen vielversprechenden Ansatz dar, um den aktuellen Herausforderungen im internationalen Wettbewerb zu begegnen.

Prof. Bernd-Arno Behrens

Zur Anwendung von Machine Learning beim Schmieden ist eine Integration der Daten über alle Teilprozesse hinweg erforderlich, um die komplexen Wechselwirkungen vollständig zu ergründen.

Julius Peddinghaus

Ohne eine zwingende physikalische Erklärbarkeit von Machine-Learning-Methoden besteht zudem ein bedeutendes Potenzial darin, ungenutzte Datenströme zu erschließen.

Dr. Kai Brunotte

AUTOREN

Julius Peddinghaus, M.Sc.

ist Bereichsleiter Massivumformung
am Institut für Umformtechnik und
Umformmaschinen (IFUM)
an der Leibniz Universität Hannover

Dr.-Ing. Kai Brunotte

ist Oberingenieur
am Institut für Umformtechnik und
Umformmaschinen (IFUM)
an der Leibniz Universität Hannover

Marcel Rothgänger, M.Sc.

ist Fachbereichsleiter SCALE
am Institut für Umformtechnik und
Umformmaschinen (IFUM)
an der Leibniz Universität Hannover

Prof. Dr.-Ing. Bernd-Arno Behrens

leitet das Institut für Umformtechnik
und Umformmaschinen (IFUM)
an der Leibniz Uni-versität Hannover

Dr.-Ing. Lennart Hinz

ist Arbeitsgruppenleiter Industrielle
und Medizinische Bildverarbeitung
am Institut für Mess- und Regelungstechnik
(IMR) an der Leibniz Universität Hannover

Pascal Kern

ist wissenschaftlicher Mitarbeiter
am Institut für Mess- und Regelungstechnik
(IMR) an der Leibniz Universität Hannover

Bisher wurden KI-Methoden vor allem auf Teilsystemebene verwendet. Der Schwerpunkt liegt meist auf individuellen Teilprozessen innerhalb der Produktionskette, geprägt durch wenig Wechselwirkungen mit vor- und nachgelagerten Prozessen. Beispiele sind etwa die Handhabung und die Zerspanung [1].

Eine Herausforderung des Data Mining beim Schmieden ist die Vielzahl an Wechselwirkungen zwischen den einzelnen Prozessschritten, wie Erwärmung, Schmierstoffapplikation und Vorformgebung, welche die finale Formgebung beeinflussen. Zur Anwendung von ML beim Schmieden ist demnach eine Integration der Daten über alle Teilprozesse hinweg erforderlich, um die komplexen Wechselwirkungen vollständig zu ergründen. Durch KI- und ML-Algorithmen werden alle erfassten Prozessgrößen direkt mit der Schmiedeteilqualität verknüpft und korreliert. Ziel ist es, ein besseres Verständnis dafür zu entwickeln, wie Veränderungen in den Stell- und Prozessgrößen die Qualität der hergestellten Bauteile beeinflussen.

Ein Nachteil des rein empirischen Ansatzes ist, dass Ergebnisse ohne Berücksichtigung physikalischer Zusammenhänge generiert werden. Gleichzeitig hat dieser Ansatz jedoch den Vorteil, dass Vereinfachungen und Annahmen der konventionellen Modellierung umgangen werden können. Auf diese Weise können ML-Modelle die Wirkzusammenhänge genauer modellieren, ohne dass sämtliche Effekte physikalisch erklärbar sein müssen. Eine vollständige Automatisierung des Prozesses bildet die Grundlage für das Data Mining. Mit zunehmendem Produktionsvolumen werden Modelle kontinuierlich präziser, vorausgesetzt, dass Bauteilqualitätsmerkmale für jedes Teil erfasst werden.

Etablierte Qualitätssicherungsmethoden basieren meist auf der stichprobenhaften Erfassung von Qualitätsmerkmalen, insbesondere der Geometrie. Beim Schmieden stellt die Zuordnung von Datensätzen nach der Abkühlung der Schmiedeteile in Sammelbehältern eine erhebliche Herausforderung dar, da die Reihenfolge und Zuordnung der Daten verloren geht. Eine vielversprechende Alternative ist die Messung direkt nach dem Schmieden im warmen Zustand. Das bietet den zusätzlichen Vorteil einer schnelleren Erfassung von Abweichungen, wodurch Ausschuss effektiv vermieden wird. Optische Messverfahren sind hier vorzuziehen, da sie eine schnelle Datenerfassung sowie hohe Datendichte bieten.

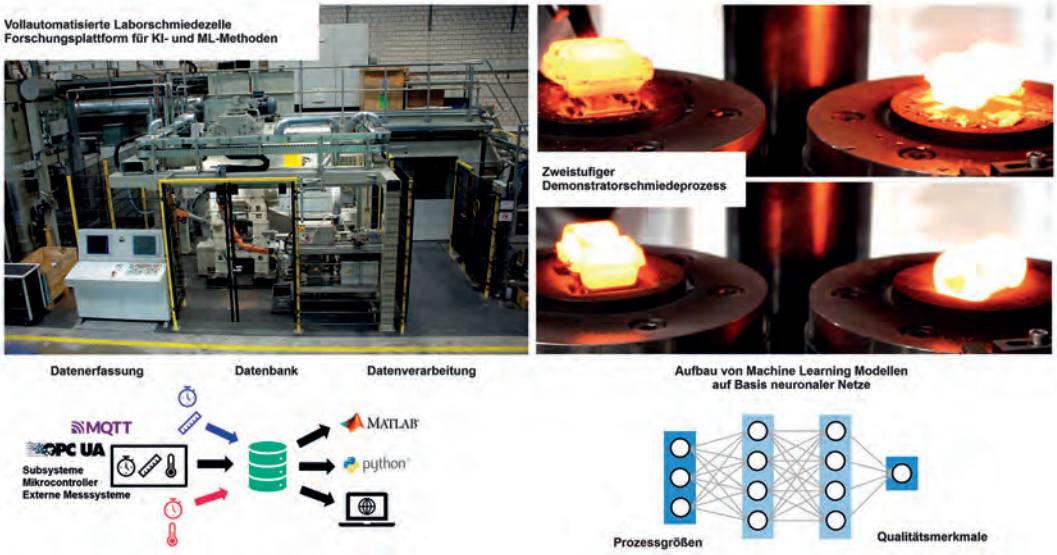

Bild 1: Laborschmiedezelle und Demonstratorprozess zur Entwicklung von KI-Methoden für das Gesenkschmieden (oben), Schematische Prinzipdarstellung von Prozessdateninfrastruktur und Neuronalen Netzen (unten)

Als messtechnische Ansätze kommen Laserliniensensoren und Streifenlichtprojektion in Frage. Hochtemperaturfähige Liniensensoren sind bereits auf dem Markt verfügbar und erfordern einen geringen Investitionsaufwand. Durch Relativbewegung des Sensors zum Bauteil wird aus einem zweidimensionalen Linienprofil eine dreidimensionale Oberfläche erstellt. Im Rahmen von Arbeiten am IFUM konnten bereits vereinfachte ML-Algorithmen genutzt werden, um die erfasste Gratform mit beispielsweise der Prozesstemperatur und der Umformkraft zu korrelieren [2]. Über den Forschungskontext hinaus werden bereits schlüsselfertige Messsysteme zur Vermessung schmiedewarmer Bauteile, zum Beispiel durch den Hersteller KELK.

Als alternative Methode stellt die Streifenlichtprojektion den aktuellen Status quo in der Kaltvermessung dar. Sie bietet den Vorteil, komplette Oberflächen schnell und präzise zu erfassen. Durch den Einsatz eines Projektors und einer Kamera aus unterschiedlichen Perspektiven können dreidimensionale Oberflächen aufgenommen werden. Im Rahmen des Sonderforschungsbereichs 1153 arbeitet das Institut für Mess- und Regelungstechnik (IMR) zusammen mit dem IFUM daran diese Technologie für die Warmteilvermessung zu befähigen. Die wesentliche Herausforderung ist das temperaturabhängige Brechungsindexfeld, das durch die Wärmeabgabe an die Luft entsteht und so den Lichtstrahlengang verändert und die Ergebnisse verfälscht. Um diesen Effekt zu kompensieren, wurde ein Messsystem entwickelt. Es setzt mehrere Kameras mit zusätzlicher Luftanströmung zur Homogenisierung ein. Mittels Simulation wird zudem ein Ersatzmodell für die Lichtablenkung im Brechungsindexfeld berechnet. Die Machbarkeit dieser Methoden wurde bereits dezentral nachgewiesen, derzeit wird die inline-Messung im Serienbetrieb erprobt [3].

Bei datenbasierten Methoden benötigen die erfassten Daten keine hohe Absolutgenauigkeit oder Erklärbarkeit in ihrem Zusammenhang. Messtechnisch bedingte Offsets und Nicht-Linearitäten können durch ML-Modelle direkt berücksichtigt werden, sodass diese sich nicht negativ auf die Prognosegüte auswirken. Die Gefahr von Fehlinterpretationen durch zufälliges Rauschen nimmt mit zunehmender Zahl an Datensätzen ab. Durch die reduzierten Anforderungen an physikalische Exaktheit können einfachere Sensorkonzepte eingesetzt werden, was eine breitere und kostengünstigere Datenerfassung ermöglicht.

Ein Beispiel hierfür ist die Temperaturmessung. Thermografie erfasst Oberflächentemperaturen berührungslos, doch Emissivität, Reflexionen, Blickwinkel und Kameradrift verfälschen Absolutwerte. Da für ein ML-Modell der Einfluss der erfassten Werte und nicht der Absoluttemperatur auf das Ergebnis entscheidend ist, sind diese Nachteile von untergeordneter Bedeutung. Bei ausreichender Datenmenge kann das Modell beschreiben, wie diese Werte die resultierende Qualität beeinflussen. Ähnlich verhält sich die Erfassung der Umformkraft, welche typischerweise mithilfe von Dehnungsmesstreifen am Pressengestell oder im Werkzeugaufbau erfolgt. Die Kalibrierung und die Nicht-Linearität limitieren die Präzision der Messung. Ohne Bedarf an

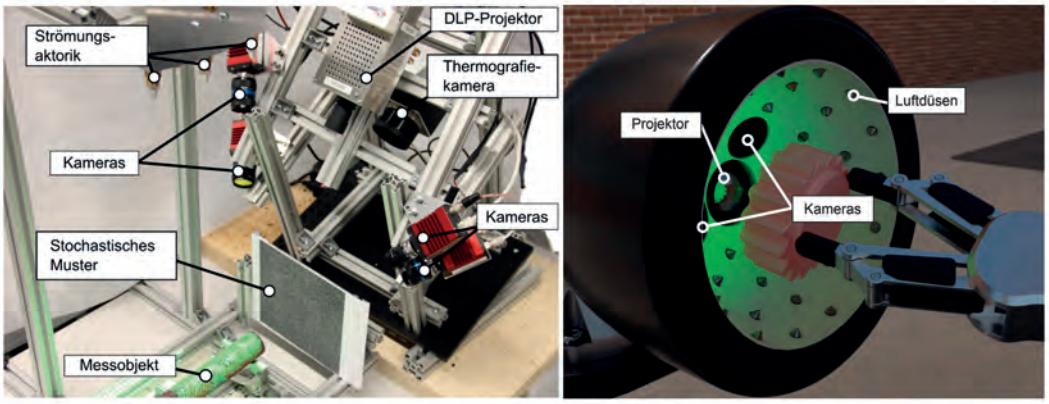

Bild 2: Experimenteller Aufbau eines Heißteilmesssystems (links), Konzept ei-nes Heißteilmesssystems für die Serienanwendung (rechts)
Bild 3: Beispielhafte inline-Datenaufzeichnung aus der übergeordneten Anlagensteuerung (links) und von Zeitreihendaten eines Schmiedeprozesses (rechts), Bilder: Autoren

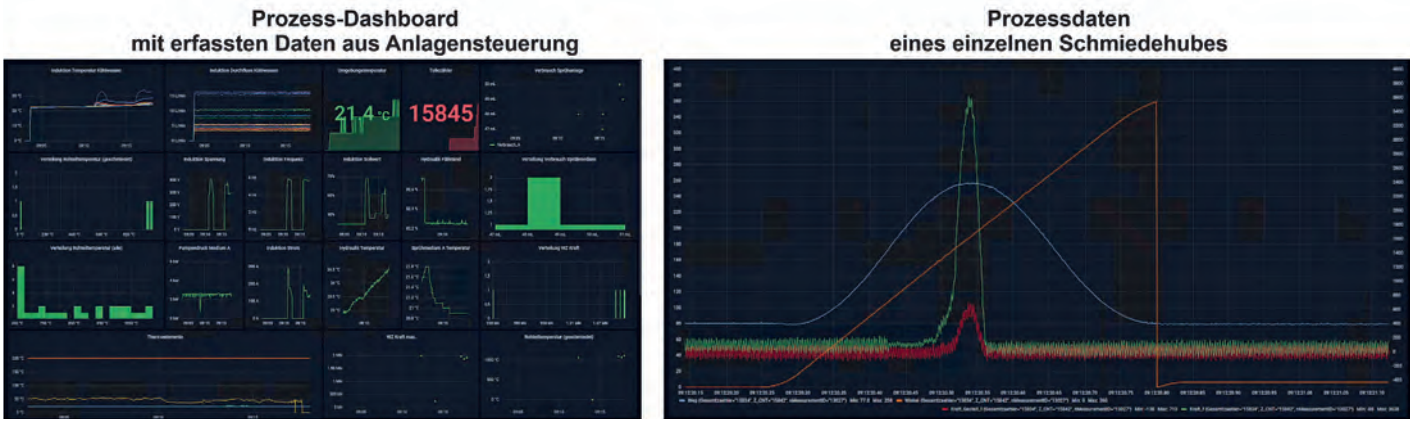

Bild 3: Beispielhafte inline-Datenaufzeichnung aus der übergeordneten Anlagensteuerung (links) und von Zeitreihendaten eines Schmiedeprozesses (rechts), Bilder: Autoren

absoluter Genauigkeit für das Training von ML-Methoden werden auch hier die messtechnischen Hürden umgangen.

Ohne eine zwingende physikalische Erklärbarkeit von ML-Methoden besteht zudem ein bedeutendes Potenzial darin, ungenutzte Datenströme zu erschließen. Diese Datenströme umfassen Informationen, die schwer interpretierbar sind, sich jedoch durch die Empirik des maschinellen Lernens nutzen lassen. Automatisierte Umgebungen erfordern zur Überwachung den Einsatz einer Vielzahl von Sensoren. Die Komplexität der Wechselwirkungen dieser Größen mit dem Prozessergebnis stellt die Analytik vor Herausforderungen, insbesondere wenn es um die Erklärbarkeit der Zusammenhänge geht. Ein Beispiel dafür ist, wie Pumpendrücke in Sprühsystemen sich indirekt auf die Qualität des gefertigten Bauteils auswirken können. Diese Beziehungen sind analytisch nur schwer direkt zu erklären. Durch den Einsatz empirischer Korrelationen in ML-Modellen können solche unkonventionellen Daten trotzdem genutzt werden. Diese Modelle können Zusammenhänge beschreiben, ohne dass jede Kausalität physikalisch erklärt werden muss. Ähnliche Potenziale bestehen unter anderem auch bei der Erfassung von Temperaturen in Kühlwasserkreisläufen oder bei elektrischen Daten von Antrieben in Pressen und Robotern.

[1] Gao, R.X.; Krüger, J.; Merklein, M.; Möhring, H.-C.; Váncza, J.: Artificial Intelligence in manufacturing: State of the art, perspectives, and future directions, CIRP An-nals, Vol. 73, Nr. 2, 2024

[2] Glaubitz, C.; Rothgänger, M.; Ortlieb, E.; Peddinghaus, J.; Brunotte, K.: Laser triangulation for quality monitoring in automated series forging processes: A method for evaluating the component quality feature 'flash', Materials Research Proceedings, 54, 2025

[3] Kern, P.; Hinz, L.; Kästner, M.; Reithmeier, E.; Blankemeyer, S.; Ince, C.-V.; Raatz, A.; Behrens, B.-A.; Brunotte, K.; Uhe, J.: Prozessoptimierung mittels Inline-Geometriemessung – Automatisierung und Digitalisierung in Tailored-Forming-Prozessketten, wt Werkstattstechnik online, Vol. 113, Nr. 10, 2023

Um diese Daten effektiv für das Training von ML-Modellen zu nutzen, ist eine Verknüpfung von Anlagensteuerungen mit Datenbankinfrastruktur notwendig. Durch Schnittstellen können die generierten Sensordaten erfasst, gebündelt und für weiterführende Analysen genutzt werden. Diese Integration ermöglicht es, das volle Potenzial bestehender Sensorik auszuschöpfen und die Entwicklung von Prozessen weiter voranzutreiben, ohne zusätzliche Sensoren zu integrieren.

In den vergangenen Jahren wurde die Schmiedeinfrastruktur am IFUM für das Data Mining und die Forschung an KI- und ML-Methoden erweitert. Ziel ist, eine robuste Datengrundlage zu schaffen, um datenbasierte Methoden belastbar zu testen und diese für das Schmieden weiterzuentwickeln.

Die Autoren bedanken sich für die Unterstützung der Deutschen Forschungsgemeinschaft (DFG) im Rahmen des Projektes 520195047 sowie der Teilprojekte B02, B03, C01, C05 und T08 im Projekt Nr. 252662854 für diese Forschungsarbeit.

Gefördert durch:

Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

Gefördert durch

DFG Deutsche Forschungsgemeinschaft