

Ⓐ Anwendungen des maschinellen Lernens in der Produktion aus Auftrags- und Produktsicht

Ein Überblick

*Berend Denkena,
Marc-André Dittrich,
Hendrik Noske*,
Kathrin Kramer und
Matthias Schmidt*

Das maschinelle Lernen als Teilgebiet der Künstlichen Intelligenz kann in der Fertigung dazu beitragen, Prozesse beschleunigt auszulegen, Zykluszeiten und Ausschuss zu reduzieren und Produktionskapazitäten besser auszuschöpfen. Dieser Beitrag gibt einen systematisierten Überblick über Anwendungen des maschinellen Lernens für produkt- und auftragsbezogene Prozesse und unterstützt Praxisanwender dabei, Einsatzfelder gezielt zu identifizieren und Wertschöpfungspotenziale zu erschließen.

Einleitung

Produzierende Unternehmen stehen durch den globalen Handel unter einem steigenden Konkurrenzdruck und sind so gezwungen, Produktionsprozesse so effizient wie möglich auszulegen. Zudem steigt der Bedarf an innovativen, wertsteigernden Produkten und Dienstleistungen, welche sich in einer steigenden Komplexität von Produktionssystemen widerspiegeln [1]. Gleichzeitig werden durch die zunehmende Sensorintegration im Zuge der Industrie 4.0 zunehmend Daten gesammelt [2]. So wurden in der Vergangenheit sensorische Komponenten entwickelt, mit deren Hilfe Fertigungsprozesse überwacht und Daten akquiriert werden können. Hierzu gehören beispielsweise fühlende Spindelschlitten, fühlende Werkzeugaufnahmen oder fühlende Spannsysteme [3, 4]. Aufgrund

der Masse an verfügbaren Daten und der steigenden Komplexität der Produktionsprozesse ist eine Analyse der Daten mithilfe konventioneller Methoden nicht mehr durchführbar [5]. In diesem Kontext können Verfahren des maschinellen Lernens dazu beitragen, dass Produktionssysteme lernen und sich veränderten Umweltbedingungen anpassen [5]. Diese Methoden ermöglichen es, komplexe Muster in hochdimensionalen Daten zu extrahieren und beispielsweise für Vorhersagen einzusetzen [6]. In der Vergangenheit wurden zahlreiche freie Softwareumgebungen entwickelt, die die einfache Implementierung dieser Methoden erlauben [7]. Mithilfe dieser Programme ist ein schneller Vergleich verschiedener Methoden möglich, ohne einzelne Methoden programmieren zu müssen. Ein weiterer Treiber der Anwendung dieser Modelle ist die stetig steigende Rechnerleistung [5].

Nach der Art des Trainings der Modelle werden drei Kategorien des maschinellen Lernens unterschieden. Beim Überwachten Lernen ist ein Datensatz mit den richtigen Ergebnissen vorhanden. Zu dieser Kategorie gehören Regressionsmethoden zur Vorhersage eines kontinuierlichen Ausgabewertes, während im Rahmen der Klassifikation ein diskreter Ausgabewert

vorhergesagt wird. Das Unüberwachte Lernen verfügt im Gegensatz zum Überwachten Lernen nicht über bekannte Ausgabewerte. Es handelt sich daher um ein Vorgehen zur Kategorisierung bzw. Segmentierung von Daten. Im Rahmen des Verstärkenden Lernens erlernt ein Agent eine Strategie anhand von Belohnungen oder Bestrafungen für die Ausführung bestimmter Aktionen [6, 7, 8].

Es existieren zahlreiche Reviews, die spezifische Einsatzfelder von Methoden des maschinellen Lernens in der Fertigung isoliert aufzeigen [5, 9–15]. Allerdings mangelt es an einer übergeordneten Betrachtungsweise des Implementierungsfortschritts dieser Methoden in der Produktion. Ziel des Beitrags ist es daher, einen systematisierten Überblick über Anwendungen des maschinellen Lernens für produkt- und auftragsbezogene Prozesse zu geben. Die produktbezogene Sichtweise betrachtet dabei die Arbeitsvorbereitung sowie die Überwachung der eigentlichen Fertigung, während die auftragsbezogene Sichtweise Prozesse wie die Produktionsplanung und -steuerung einschließt. Der vorliegende Überblick soll produzierende Unternehmen dabei unterstützen, Einsatzfelder datenbasierter Ansätze gezielt zu identifizieren und Wertschöpfungspotenziale zu erschließen.

* Korrespondenzautor

Hendrik Noske, M.Sc.
Institut für Fertigungstechnik
und Werkzeugmaschinen
Leibniz Universität Hannover
An der Universität 2, 30823 Garbsen
Tel.: +49 (0) 511 762-5997
E-Mail: noske@ifw.uni-hannover.de

Auftrags- und produktbezogene Prozesse in der Produktion

Zur Systematisierung der Einsatzfelder des maschinellen Lernens in der Fertigung sind zunächst sämtliche Prozesse zu betrachten, die von Produktionsunternehmen in der Regel durchzuführen sind. In Bild 1 werden produktbezogene und auftragsbezogene Prozesse unterschieden. Die produktbezogenen Prozesse beinhalten diejenigen Schritte die ein spezifisches Produkt betreffen. Nach der Entwicklungsphase erfolgt im Rahmen der Konstruktion die Erstellung einer Konstruktionszeichnung. Auf dieser Grundlage wird im Zuge der Prozessplanung (auch Arbeitsplanung genannt) ein Arbeitsplan erstellt, auf dessen Basis die eigentliche Fertigung durchgeführt wird [16]. Während des Fertigungsprozesses findet die Prozessüberwachung zur Detektion von Anomalien sowie die Zustandsüberwachung zur Überwachung einzelner Maschinenkomponenten statt. Schließlich erfolgt die Qualitätskontrolle in der die vom Kunden vorgegebenen Qualitätskriterien überprüft werden.

In der Praxis sowie in der Wissenschaft werden die dem Auftragsdurchlauf zugehörigen Aufgaben unterschiedlich beschrieben [17, 18]. Bild 1 stellt in Anlehnung an das Hannoveraner Lieferkettenmodell einen groben Ablauf als Referenz dar. Die auftragsbezogene Prozesskette beginnt mit der Produktionsplanung, in der beispielsweise Fragestellungen zu dem erwarteten Artikelabsatz oder dem Fremdbeschaffungs- und Eigenfertigungsanteil beantwortet werden. Darauf aufbauend bzw. ab einer gewissen Planungsbasis parallel zur Planung, erfolgt die Beschaffung von Zukaufteilen. Die Produktionssteuerung beinhaltet die Steuerung der Eigenfertigung mit dem Ziel, auf von der Planung abweichende Faktoren (z.B. Lieferverzögerung von Material, Anlagenstörung) unter bestmöglicher Einhaltung produktionslogistischer Zielgrößen zu reagieren. Das Produktionscontrolling umfasst schließlich den Abgleich zwischen Plan- und Ist-Werten der Betriebsrückmeldedaten aus der unternehmensinternen Lieferkette, um Maßnahmen für eine optimierte Produktionsplanung und -steuerung ableiten zu können. Ist der Produktionsauftrag fer-

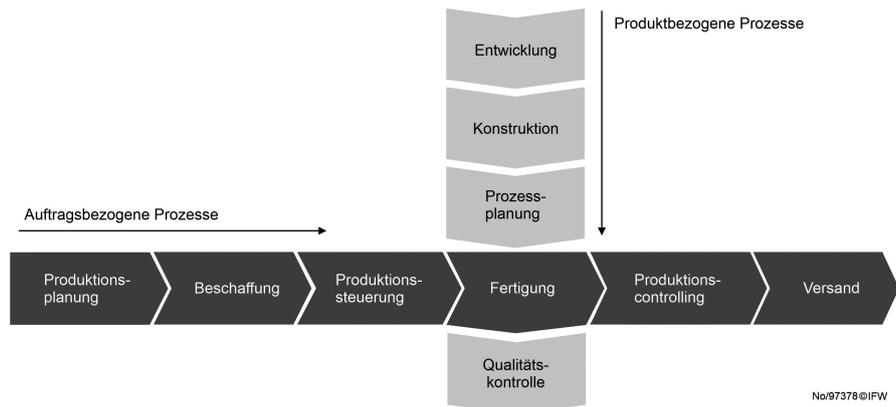


Bild 1. Überblick über auftrags- und produktbezogene Prozesse in der Fertigung [16-18]

tiggestellt, wird der Artikel nach einer eventuellen Einlagerung an den Kunden versandt [18].

Produktbezogene Prozesse und zugehörige Einsatzfelder des maschinellen Lernens

Im Rahmen der produktbezogenen Prozesse sind verschiedene Einsatzfelder des maschinellen Lernens vorzufinden. Im Folgenden wird die Zerspanung als beispielhafter Fertigungsprozess angeführt und somit die verschiedenen Anwendungsfelder für produktspezifische Prozesse konkreter skizziert (Bild 2).

Ein Einsatzfeld umfasst die Prozessplanung, die zwischen der Konstruktion und der Fertigung angesiedelt ist. Die Prozessplanung umfasst Aktivitäten zur Planung der Fertigung von Bauteilen auf Basis vorgegebener Spezifikationen [16]. In der Prozessplanung werden mithilfe von maschineller Lernverfahren offline industrierelevante Qualitätszielgrößen vorhergesagt. Zu den industrierelevanten

ten Zielgrößen gehören in der Zerspanung u.a. die Werkzeugstandzeit, die Oberflächenrauheit, der Formfehler, Schnittkräfte sowie die Stabilität [13, 19, 20]. Die realisierten Zielgrößen werden nach der eigentlichen Fertigung im Rahmen der Qualitätskontrolle erfasst. Für die Vorhersage werden Regressionsmodelle wie Künstliche Neuronale Netze oder Support Vector Machines eingesetzt. Liegen Qualitätsklassen vor, so kommen Klassifikationsmodelle zum Einsatz [21]. Eine weitere Aufgabenkategorie der Prozessplanung beschäftigt sich mit der Bestimmung optimaler Prozessstellgrößen bei vorgegebener Zielgröße [21, 22]. Prozessstellgrößen in der Zerspanung umfassen die Schnittgeschwindigkeit, Vorschub, Schnitttiefe etc. Eine häufig zu minimierende Zielgröße ist beispielsweise die Oberflächenrauheit. Dabei beschränken sich diese Ansätze nicht nur auf eine Zielgröße, sondern beziehen teilweise mehrere Zielgrößen wie die Werkzeugstandzeit oder das Zeitspanvolumen mit ein [23-25]. Für die Bestimmung op-

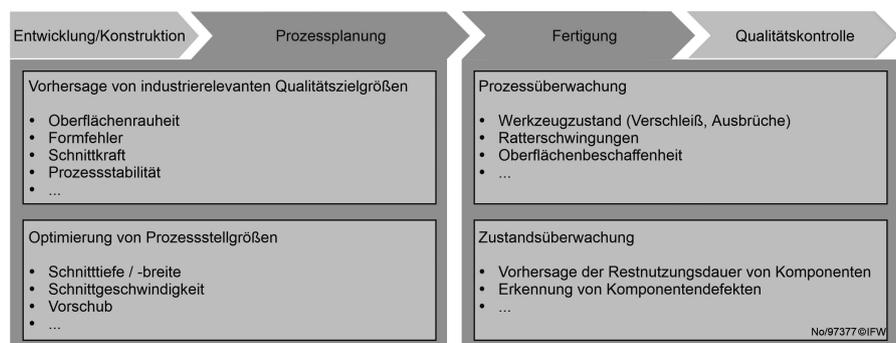


Bild 2. Produktspezifische Einsatzfelder des maschinellen Lernens am Beispiel der spanenden Fertigung

timaler Prozessstellgrößen werden beispielsweise Optimierungsverfahren wie Genetische Algorithmen, Simulated Annealing oder die Partikelschwarmoptimierung eingesetzt [23]. Im technischen Fertigungsprozess finden maschinelle Lernverfahren im Bereich der Prozess- und Zustandsüberwachung Anwendung. Bei der Prozessüberwachung eignen sich Regressionsmodelle für die Vorhersage von Qualitätszielgrößen anhand von Prozessstellgrößen und Sensordaten. Zudem können anhand von Sensordaten Prozessanomalien erkannt werden, wie beispielsweise Schneidkanten und -schaftbrüche sowie Prozessinstabilitäten [26, 27]. Die Zustandsüberwachung hingegen ist die Voraussetzung für eine zustandsorientierte Wartung von Maschinen und Anlagen. In der Literatur ist eine Vielzahl von Ansätzen zur Überwachung von Komponenten wie Lager, Getriebe, Wellen, Pumpen etc. zu finden. Ansätze des maschinellen Lernens werden beispielsweise zur Prognose der Restnutzungsdauer von Komponenten sowie zur Diagnose von Ausfallursachen eingesetzt [28]. Deep-Learning Ansätze haben in den letzten Jahren an Popularität in der Zustandsüberwachung gewonnen. Diese Methoden sind in der Lage, im Gegensatz zu traditionellen Lernverfahren natürliche Daten wie Bilder, Sprache oder Videos verarbeiten, ohne das Merkmale manuell extrahiert werden müssen [29]. Liegen in der Prozess- und Zustandsüberwachung Fehlerklassen vor, werden Klassifikationsmodelle zur Evaluation von Fertigungsprozessen oder des Komponentenzustands eingesetzt. Konkrete Fehlerklassen sind in der Fertigung jedoch nicht immer verfügbar. Alternativ bestehen Ansätze in der Literatur, die der Gruppe der semi-überwachten Anomalieerkennung zuzuordnen sind. So können mithilfe eines „Fingerabdrucks“ Zustände von Maschinenkomponenten auch bei fehlenden Fehlerzuständen überwacht werden [30].

Auftragsbezogene Prozesse und zugehörige Einsatzfelder des maschinellen Lernens

Bei den auftragsbezogenen Prozessen existieren ebenfalls zahlreiche Einsatzfelder des maschinellen Lernens. In der

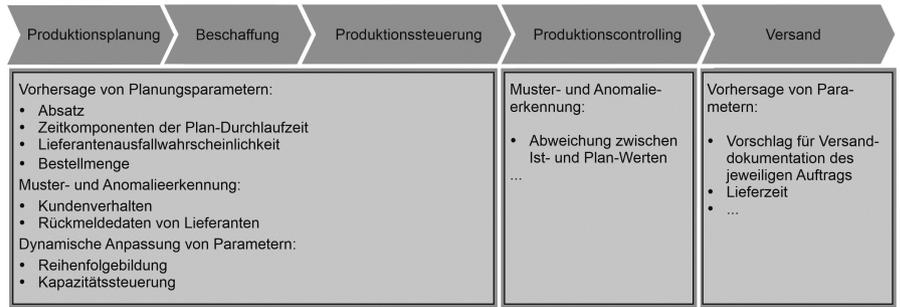


Bild 3. Auftragspezifische Einsatzfelder des maschinellen Lernens

Regel beziehen sich diese Anwendungen auf die Erfüllung oder Unterstützung spezifischer Teilaufgaben mit dem übergeordneten Ziel einer effizienten und effektiven Auftragsorganisation. Gängige Anwendungsfelder sind bei der Produktionsplanung, Beschaffung, Produktionssteuerung, Produktionscontrolling und Versand vorzufinden [14, 15]. Bild 3 stellt dies übersichtlich dar.

Im Rahmen der Produktionsplanung wird das maschinelle Lernen insbesondere zur Absatzprognose, Bestandsdimensionierung und der Eigenfertigungsplanung eingesetzt [14]. Bei der Absatzprognose dienen Verfahren des Überwachten Lernens zur Absatzprognose von Produktgruppen, Produkten oder Teilen [31]. Das Ergebnis kann wiederum bei nachgelagerten Produktionsplanungsaufgaben berücksichtigt werden und die Planungsqualität bei der Beschaffung, Bestandsdimensionierung und Eigenfertigungsplanung positiv beeinflussen. Beispielsweise kann das Zeitfenster prognostiziert werden bei dem ein Artikel von einem Schnelldreher zu einem Langsamdreher wird und demzufolge die Bestellpolitik anzupassen ist [32]. Ferner kann mittels Unüberwachter Verfahren das Kundenverhalten untersucht werden. Eine Kundensegmentierung kann zum Beispiel Kundenbedürfnisse herausstellen, welche bei der Produktentwicklungsphase berücksichtigt werden. Im Produktionsumfeld gibt es hierzu jedoch nur wenige Fallbeispiele [15]. Des Weiteren sind maschinelle Lernverfahren bei der Eigenfertigungsplanung zur Bestimmung von Zeitkomponenten (z.B. Störzeiten, Übergangszeiten) oder Produktionslosgrößen einzusetzen. Die Prognose von Zeitkomponenten präzisiert die Bestimmung von

Plan-Auftragsdurchlaufzeiten und ermöglicht demnach eine verlässlichere Durchlaufterminierung [33]. Bei der Beschaffung können maschinelle Lernverfahren zur Bestimmung der Bestellmenge als auch beim Lieferanten-Sourcing und Monitoring eingesetzt werden. Beispielsweise können in komplexen Supply Chain Strukturen Anomalien hinsichtlich der Rückmeldedaten der Lieferanten untersucht, voraussichtliche Lieferzeiten prognostiziert oder Lieferantenausfallwahrscheinlichkeiten berechnet werden [33, 35]. In einem weiteren Aufgabenfeld, der Produktionssteuerung, liegt der Forschungsschwerpunkt auf der Reihenfolgebildung [14]. Es sollen die Arbeitsvorgänge der Aufträge auf der richtigen Maschine zum richtigen Zeitpunkt unter Berücksichtigung definierter Kriterien eingeplant werden. Lösungsansätze nutzen das Prinzip des Verstärkten Lernens und trainieren einen Agenten mittels einer Zielfunktion (z.B. Gewinnmaximierung). Resultierend kann die Reihenfolgeplanung dynamisch an die Situation in der Fertigung angepasst werden [36, 38]. Das Produktionscontrolling kann durch Verfahren des Unüberwachten Lernens unterstützt werden, indem Anomalien und spezifische Muster erkannt werden. Es lassen sich Abweichungen von den Rückmeldedaten im Vergleich zu den Plan-Werten identifizieren und diese hinsichtlich ihrer Ursachen untersuchen (z. B. Abweichung aufgrund eines Eingabefehlers) [5, 14, 39]. Im letzten auftragsbezogenen Prozessschritt, dem Versand, können maschinelle Lernverfahren ebenfalls bei der Aufgabenerfüllung (z.B. bei der Ausfertigung von Versanddokumenten oder Auswahl der Verpackungart) unterstützen [37].

Zusammenfassung

Die Beschreibung der produkt- und auftragsbezogenen Prozessschritte verdeutlicht die enge Verzahnung dieser Prozesse und dessen gemeinsame Auswirkung auf die Erreichung der Unternehmensziele. Die Methoden des maschinellen Lernens bieten vielfältige Einsatzfelder in der Fertigung. Domänen-Experten müssen in die Lage versetzt werden, Einsatzfelder zu identifizieren und Wertschöpfungspotenziale zu bewerten. In diesem Beitrag wurden daher Einsatzfelder des maschinellen Lernens für produkt- und auftragsbezogene Prozesse vorgestellt und systematisiert. In zukünftigen Forschungsvorhaben sollte die enge Vernetzung der auftrags- und produktbezogenen Prozesse näher untersucht werden. Beispielsweise kann die Implementierung einer Prozessüberwachung dazu beitragen, fehlerhafte Bauteile zu erkennen. Auf Basis dieser Erkenntnis können Prozessparameter im Rahmen der Prozessplanung angepasst werden. Die Auftragsorganisation profitiert wiederum von verkürzten Auftragsdurchlaufzeiten, da der Nachbearbeitungsaufwand reduziert werden kann [19]. Wie das Beispiel illustriert, trägt ein übergreifendes Prozessverständnis dazu bei, die Auswirkungen auf unterschiedliche Bereiche zu erkennen und ganzheitliche Wertschöpfungspotenziale zu identifizieren.

Literatur

- Wuest, T.: Identifying Product and Process State Drivers in Manufacturing Systems Using Supervised Machine Learning. Springer International Publishing, Berlin 2015
DOI: 10.1007/978-3-319-17611-6
- Krüger, J.; Fleischer, J.; Franke, J.; Groche, P.: WGP-Standpunkt, KI in der Produktion - Künstliche Intelligenz erschließen für Unternehmen. WGP - Wissenschaftliche Gesellschaft für Produktionstechnik e. V., 2019
- Denkena, B.; Boujnah, H.: Feeling Machines for Online Detection and Compensation of Tool Deflection in Milling. CIRP Annals 67 (2018) 1, S. 423-426
DOI: 10.1016/j.cirp.2018.04.110
- Möhring, K.-C.; Litwinski, K.M.; Gümmer, O.: Process Monitoring with Sensory Machine Tool Components. CIRP Annals 59 (2010) 1, S. 383-386
DOI: 10.1016/j.cirp.2010.03.087
- Wuest, T.; Weimer, D.; Irgens, C.; Thoben, K.-D.: Machine Learning in Manufacturing: Advantages, Challenges, and Applications. Production & Manufacturing Research 4 (2016) 1, S. 23-45
DOI: 10.1080/21693277.2016.1192517
- Alpaydin, E.: Introduction to Machine Learning. MIT Press, Cambridge, London 2010, S. 1-13
- Software und Digitalisierung: Quick Guide - Maschine Learning im Maschinen- und Anlagenbau. VDMA Software und Digitalisierung, 2018
- Brownlee, J.: Master Machine Learning Algorithms: Discover How They Work and Implement Them From Scratch. 2016
- Pham, D. T.; Afify, A. A.: Machine-learning Techniques and Their Applications in Manufacturing. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture 219 (2005) 5, S. 395-412
DOI: 10.1243/095440505X32274
- Monostori, L.; Markus, A.; van Brussel, H.; Westkämpfer, E.: Machine Learning Approaches to Manufacturing. CIRP Annals 45 (1996) 2, S. 675-712
DOI: 10.1016/S0007-8506(18)30216-6
- Harding, J. A.; Shahbaz, M.; Srinivas S.; Kusiak, A.: Data Mining in Manufacturing: A Review. Journal of Manufacturing Science and Engineering 128 (2006) 4, S. 969-976
DOI: 10.1115/1.2194554
- Wang, J.; Ma, Y.; Zhang, L.; Gao, X.; Wu, D.: Deep Learning for Smart Manufacturing: Methods and Applications. Journal of Manufacturing Systems 48 (2018), S. 144-156
DOI: 10.1016/j.jmsy.2018.01.003
- Köksal, G.; Batmaz, İ.; Testik, M. C.: A Review of Data Mining Applications for Quality Improvement in Manufacturing Industry. Expert Systems with Applications 38 (2011) 10, S. 13448-13467
DOI: 10.1016/j.eswa.2011.04.063
- Schmidt, M.; Maier, J. T.; Grothkopp, M.: Eine bibliometrische Analyse: Produktionsplanung und -steuerung und maschinelles Lernen. wt Werkstattstechnik online 110 (2020) 4, S. 220-225
DOI: 10.37544/1436-4980-2020-04-54
- Usuga Cadavid, J. P.; Lamouri, S.; Grabot, B.; Pellerin, R.; Fortin, A.: Machine Learning Applied in Production Planning and Control: A State-of-the-Art in the Era of Industry 4.0. Journal of Intelligent Manufacturing 31 (2020) 6, S. 1531-1558
DOI: 10.1007/s10845-019-01531-7
- Eversheim, W.: Organisation in der Produktionstechnik 3. Springer-Verlag, Berlin, Heidelberg 1997
DOI: 10.1007/978-3-642-97974-3
- Wiendahl, H.-P.: Betriebsorganisation für Ingenieure. Carl Hanser Verlag, München, Wien 2014
DOI: 10.3139/9783446441019
- Schmidt, M.; Schaefers, P.: The Hanoverian Supply Chain Model: Modelling the Impact of Production Planning and Control on a Supply Chain's Logistic Objectives. Production Engineering 11 (2017) 4-5, S. 487-493
DOI: 10.1007/s11740-017-0740-9
- Arrazola, P. J.; Özel, T.; Umbrello, D.; Davies, M.; Jawahir, I. S.: Recent Advances in Modelling of Metal Machining Processes. CIRP Annals 62 (2013) 2, S. 695-718
DOI: 10.1016/j.cirp.2013.05.006
- Dittrich, M.-A.; Uhlich, F.; Denkena, B.: Self-optimizing Tool Path Generation for 5-Axis Machining Processes. CIRP Journal of Manufacturing Science and Technology (2019) 24, S. 49-54
DOI: 10.1016/j.cirpj.2018.11.005
- Chandrasekaran, M.; Muralidhar, M.; Krishna, C. M.; Dixit, U. S.: Application of Soft Computing Techniques in Machining Performance Prediction and Optimization: A Literature Review. The International Journal of Advanced Manufacturing Technology 46 (2010) 5-8, S. 445-464
DOI: 10.1007/s00170-009-2104-x
- Weichert, D.; Link, P.; Stoll, A.; Rüping, S.; Ihlenfeldt, S.; Wrobel, S.: A Review of Machine Learning for the Optimization of Production Processes. The International Journal of Advanced Manufacturing Technology 104 (2019) 5-8, S. 1889-1902
DOI: 10.1007/s00170-019-03988-5
- Karayel, D.: Prediction and Control of Surface Roughness in CNC Lathe Using Artificial neural Network. Journal of Materials Processing Technology 209 (2009) 7, S. 3125-3137
DOI: 10.1016/j.jmatprotec.2008.07.023
- Sedighi, M.; Afshari, D.: Creep Feed Grinding Optimization by an Integrated GA-NN System. Journal of Intelligent Manufacturing 21 (2010) 6, S. 657-663
DOI: 10.1007/s10845-009-0243-4
- Yang, S.-H.; Srinivas, J.; Mohan, S.; Lee, D.-M.; Balaji, S.: Optimization of Electric Discharge Machining Using Simulated Annealing. Journal of Materials Processing Technology 209 (2009) 9, S. 4471-4475
DOI: 10.1016/j.jmatprotec.2008.10.053
- Teti, R.; Jemielniak, K.; O'Donnell, G.; Dornfeld, D.: Advanced Monitoring of Machining Operations. CIRP Annals 59 (2010) 2, S. 717-739
DOI: 10.1016/j.cirp.2010.05.010
- Abellan-Nebot, J. V.; Romero Subirón, F.: A Review of Machining Monitoring Systems Based on Artificial Intelligence Process Models. The International Journal of Advanced Manufacturing Technology 47 (2010) 1-4, S. 237-257
DOI: 10.1007/s00170-009-2191-8
- Lee, J.; Wu, F.; Zhao, W.; Ghaffari, M.; Liao, L.; 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
DOI: 10.1016/j.ymsp.2013.06.004
29. Zhao, R.; Yan, R.; Chen, Z.; Mao, K.; Wang, P.; Gao, R. X.: Deep Learning and its Applications to Machine Health Monitoring. *Mechanical Systems and Signal Processing* 115 (2019), S. 213–237
DOI: 10.1016/j.ymsp.2018.05.050
30. Liao, L.; Lee, J.: A Novel Method for Machine Performance Degradation Assessment Based on Fixed Cycle Features test. *Journal of Sound and Vibration* 326 (2009) 3–5, S. 894–908
DOI: 10.1016/j.jsv.2009.05.005
31. Pavlyshenko, B. M.: Machine-Learning Models for Sales Time Series Forecasting. *Data* 4 (2019) 1, S. 1–11
DOI: 10.3390/data4010015
32. Hoppenheit, S.; Günthner, W. A.: Entwicklung eines Ansatzes zur proaktiven Identifikation und Bestandsplanung von langsam-drehenden Materialien. *Logistics Journal: Proceedings* (2014)
33. Burggraef, P.; Wagner, J.; Koke, B.; Steinberg, F.: Approaches for the Prediction of Lead Times in an Engineer to Order Environment – A Systematic Review. *IEEE Access* 8 (2020)
DOI: 10.1109/ACCESS.2020.3010050
34. Sremac, S.; Zavadskas, E. K.; Matic, B.; Kopic, M.; Steciv, Z.: Neuro-fuzzy Inference Systems Approach to Decision Support System for Economic Order Quantity. *Economic Research* 21 (2019) 1, S. 1114–1137
DOI: 10.1080/1331677X.2019.1613249
35. Liu, J.; Hwang, S.; Yund, W.; Boyle, L. N.; Banerjee, A. G.: Predicting Purchase Orders Delivery Times Using Regression Models With Dimension Reduction. In: *Proceedings of the ASME 2018 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*. Volume 1B: 38th Computers and Information in Engineering Conference, Quebec City, Quebec, Canada, 2018
DOI: 10.1115/DETC2018-85710
36. Echsler Minguillon, F.; Lanza, G.: Coupling of Centralized and Decentralized Scheduling for Robust Production in Agile Production systems. *Procedia CIRP* (2019) 79, S. 385–390
DOI: 10.1016/j.procir.2019.02.099
37. Knoll, D.; Neumeier, D.; Prügmeier, M.; Reinhart, G.: An Automated Packaging Planning Approach Using Machine Learning. *Procedia CIRP* 81 (2019), S. 576–581
DOI: 10.1016/j.procir.2019.03.158
38. Heger, J.; Voss, T.: Dynamically Changing Sequencing Rules with Reinforcement Learning in a Job Shop System with Stochastic Influences. In: *Proceedings of the 2020 Winter Simulation Conference* (2020), S. 1608–1618
DOI: 10.1109/WSC48552.2020.9383903
39. Reuter, C.; Brambring, F.; Weirich, J.; Kleines, A.: Improving Data Consistency in Production Control by Adaptation of Data Mining Algorithms. *Procedia CIRP* 56 (2016), S. 545–550
DOI: 10.1016/j.procir.2016.10.107

Die Autor:innen dieses Beitrags

Prof. Dr.-Ing. Berend Denkena, geb. 1959, studierte und promovierte an der Leibniz Universität Hannover im Bereich Maschinenbau. Seit 2001 leitet er das Institut für Fertigungstechnik und Werkzeugmaschinen (IFW) der Leibniz Universität Hannover.

Dr.-Ing. Marc-André Dittrich und M.Sc. Hendrik Noske sind Mitarbeiter am Institut für Fertigungstechnik und Werkzeugmaschinen (IFW) der Leibniz Universität Hannover.

Bibliography

DOI 10.1515/zwf-2021-0068
ZWF 116 (2021) 5; page 358–362
© 2021 Walter de Gruyter GmbH,
Berlin/Boston, Germany
ISSN 0947-0085 · e-ISSN 2511-0896

Prof. Dr.-Ing. habil. Matthias Schmidt, geb. 1978, studierte Wirtschaftsingenieurwesen an der Leibniz Universität und promovierte am Institut für Produktionsanlagen und Logistik (IFA) der selbigen Universität. Seit 2018 ist er Inhaber des Lehrstuhls für Produktionsmanagement am Institut für Produkt- und Prozessinnovation (PPI) der Leuphana Universität und übernahm zusätzlich 2019 die Leitung des Instituts.

Kathrin Kramer, M.Sc., ist Mitarbeiterin und Promotionsstudentin am Institut für Produkt- und Prozessinnovation (PPI) der Leuphana Universität Lüneburg.

Abstract

Applications of Machine Learning in Manufacturing from a Job Order and Product Perspective – An Overview. Machine learning as a subfield of artificial intelligence can contribute to accelerating the design of processes in manufacturing, reducing cycle times, improving quality, and making better use of production capacities. This article provides a systematized overview of machine learning applications for product- and order-related processes and supports practitioners in identifying application areas in a focused manner and exploiting value-added potential.

Schlüsselwörter

Maschinelles Lernen, Produktionsplanung und -steuerung, Produktprozesse, Produktionsmanagement, Anwendungen

Keywords

Machine Learning, Production Planning, Production Control, Order-related Processes, Product-related Processes, Use Cases

Danksagung

Gefördert vom Niedersächsischen Ministerium für Wissenschaft und Kultur unter Fördernummer ZN3489 im Niedersächsischen Vorab der VolkswagenStiftung und betreut vom Zentrum für digitale Innovationen (ZDIN).