

Maschinelles Lernen in der Produktionsplanung und -steuerung

Sophie Sautter M.Sc., Nicolai Haigis M.Sc., Manuel Baumert M.Sc., Prof. Dr.-Ing. Theo Lutz

Maschinelles Lernen verändert zusehends die Arbeitswelt. Auch in der Produktionsplanung und -steuerung finden sich vielversprechende Anwendungsfälle. In diesem Beitrag sollen ausgewählte Anwendungsbereiche und Ansätze vorgestellt werden, die anhand einer umfangreichen Untersuchung wissenschaftlicher Veröffentlichungen identifiziert wurden. Als Strukturierungshilfe dient das Aachener PPS-Modell.

Machine learning is visibly changing the world of work. Promising applications can also be found in production planning and control. This paper presents selected areas of application and approaches that have been identified through an extensive study of scientific literature. The Aachen PPC model serves as a structuring aid.

Maschinelles Lernen (englisch Machine Learning) wird in vielen verschiedenen Bereichen wie zum Beispiel der Bilderkennung, der Texterkennung oder der Datenanalyse verwendet. Viele Menschen nutzen täglich digitale Services, die auf maschinellem Lernen basieren, beispielsweise, wenn sie Google Maps zur Navigation nutzen oder in einem Onlineshop ein ergänzendes Produkt vorgeschlagen bekommen. Auch im betrieblichen Kontext finden sich immer mehr Anwendungsfälle. So wird maschinelles Lernen in der Produktionsplanung und -steuerung (PPS) beispielsweise in der Prozessoptimierung und in verschiedenen Monitoring- und Kontrollanwendungen eingesetzt [1].

Ziel dieses Artikels ist es, anhand von ausgewählten Beispielen aus einer umfangreichen Analyse wissenschaftlicher Veröffentlichungen die Möglichkeiten für den Einsatz von Machine Learning in der PPS darzustellen. Es wurden insgesamt 46 relevante peer-reviewte Veröffentlichungen aus den Jahren 2011 bis 2020 untersucht. Als Strukturierungshilfe wurden die Kernaufgaben des Aachener PPS-Modells verwendet.

Maschinelles Lernen

Machine Learning kann in drei unterschiedliche Lernmethoden unterteilt werden: das überwachte Lernen (Supervised Learning), das unüberwachte Lernen (Unsupervised Learning) sowie das bestärkende Lernen (Reinforcement Learning).

Beim überwachten Lernen lernen Machine Learning Modelle den Zusammenhang zwischen Inputdaten (sogenannte Features) wie beispiels-

weise der Außentemperatur und den Sonnenstunden an einzelnen Tagen in der Vergangenheit und Zielwerten (sogenannte Labels) wie beispielsweise der an diesen Tagen verkauften Eismenge. Ein so trainiertes Modell kann dann verwendet werden, um für Tage in der Zukunft abhängig vom Wetter die verkaufte Eismenge vorherzusagen. Beim unüberwachten Lernen existieren keine Ziellabels in den Daten. Die Modelle versuchen hier vielmehr, Ähnlichkeiten zwischen einzelnen Datenpunkten zu finden, um diese zu gruppieren. Neue Datenpunkte können dann automatisch eingeordnet werden. Beim Reinforcement Learning werden erlernte Strategien durch Feedbackmechanismen bewertet und somit der Lernprozess vorangetrieben [2].

In den untersuchten Veröffentlichungen werden alle drei Verfahren verwendet. In 18 der untersuchten Veröffentlichungen werden schwerpunktmäßig Verfahren aus dem Bereich des Supervised Learning verwendet. Unsupervised Learning wurde in 15 Veröffentlichungen angewendet, während Reinforcement Learning in 13 Veröffentlichungen genutzt wurde (Abbildung 1).



Abb. 1: Schwerpunkte der Lernmethoden in den untersuchten Veröffentlichungen

Produktionsplanung und -steuerung

Anfang der 1980er Jahre entstand das Konzept der Produktionsplanung und -steuerung (PPS), um die Material- und Zeitwirtschaft in der produzierenden Industrie übergreifend zu organisieren. Heutzutage umfasst die PPS die gesamte technische Auftragsabwicklung von der Angebotsbearbeitung bis hin zum Versand [3].

Das Aachener PPS-Modell klassifiziert die Aufgaben der Produktionsplanung und -steuerung in Kernaufgaben, Netzwerkaufgaben und Querschnittsaufgaben. Jeder der einzelnen Bereiche wird wiederum in verschiedene Unterbereiche in Form von Aufgaben gegliedert. In Abbildung 2 sind alle Bereiche des Aachener PPS-Modells zu sehen. Dieser Beitrag fokussiert den Bereich der Kernaufgaben.

Produktionsprogrammplanung

Das Ergebnis der Produktionsprogrammplanung ist der Produktionsplan. Darin wird festgehalten, welche Produkte in welchen Mengen zu festgelegten Zeitpunkten produziert werden sollen. Üblicherweise wird die Produktionsplanung in regelmäßigen Abständen getätigt und jeweils eine Periode vorausgeplant. Oft wird das mit der Auswertung der Vorperiode verbunden. Des Weiteren ist ein Rahmenbeschaffungsplan ein zusätzlicher Output der Produktionsrahmenplanung. Die wesentlichen Unteraufgaben der Produktionsprogrammplanung sind die Absatzplanung, die Primärbedarfsplanung und die Ressourcengrobplanung [3].

Im Bereich der Produktionsprogrammplanung sind bisher eher wenige wissenschaftliche Veröffentlichungen zum Einsatz von Machine Learning zu finden. Die Recherche ergab, dass im Bereich der Produktionsprogrammplanung bisher vor allem überwachte und unüberwachte Lernalgorithmen eingesetzt werden. Dabei ist in den Veröffentlichungen die Teilaufgabe Ressourcengrobplanung am stärksten vertreten. Hier wurde beispielsweise ein Modell entwickelt, das auf Grundlage vergangener Planungsaktivitäten automatisch Arbeitspläne für neue Produkte vorschlagen kann [4].

Es gibt auch einige Quellen, die den Einsatz von Machine Learning zur Erstellung eines gesamten Produktionsplans beschreiben. So zeigen Sobottka et al. für einen Anwendungsfall einer Großbäckerei, dass durch den Einsatz künstlicher neuronaler Netze im

Netzwerkaufgaben	Kernaufgaben		Querschnittsaufgaben		
Netzwerkconfiguration	Produktionsprogrammplanung		Auftragsmanagement	Bestandsmanagement	Controlling
Netzwerkabsatzplanung	Produktionsbedarfsplanung				
Netzwerkbedarfsplanung	Fremdbezugsplanung und -steuerung	Eigenfertigungsplanung und -steuerung			
Datenverwaltung					

Abb. 2: Aufgabensicht des Aachener PPS-Modells [3]

Vergleich zu manueller Planung die Zielerreichung der kostenbezogenen Planungsziele um 33 % verbessert werden kann. Die Verbesserung in Bezug auf die energiebezogenen Planungsziele beträgt 9 %. Zudem erlaubt der Ansatz eine dynamische Anpassung der Planung. Allerdings ist das Potenzial durch den Rechenaufwand bei einer Vielzahl an Produktionsaufträgen limitiert. Hier existiert weiterer Forschungsbedarf [5].

Produktionsbedarfsplanung

Die Produktionsbedarfsplanung ist dafür verantwortlich, aus dem von der Produktionsprogrammplanung erhaltenen Produktionsplan geeignete Beschaffungsprogramme zu erstellen, um den Plan realisieren zu können. Betrachtet werden dabei alle Ressourcen, die für den Produktionsprozess benötigt werden. Das sind beispielsweise Maschinen, Material, Personal oder Betriebsmittel. Die Produktionsbedarfsplanung wird in die Aufgaben Bruttobedarfsermittlung, Nettosekundärermittlung, Beschaffungsartzuordnung, Durchlaufterminierung, Kapazitätsermittlung und Kapazitätsabstimmung unterteilt [3].

In der Produktionsbedarfsplanung ist zu erkennen, dass vor allem im Bereich der Durchlaufterminierung großes Potenzial für den Einsatz von Machine Learning besteht. So beschreiben beispielsweise Lingitz et al. den Einsatz von Machine Learning in der Durchlaufterminierung in der Halbleiterfertigung. Bei der Berechnung der Durchlaufzeit auf Grundlage historischer Daten kommt es dort oft zu Problemen, da die Variabilität der Durchlaufzeiten nicht berücksichtigt wird. Die Autoren schlagen den Einsatz von Regressionsmodellen vor, die zu einer genaueren Vorhersage der Durchlaufzeiten führen [6]. In den anderen Bereichen scheint der Einsatz von Künstlicher Intelligenz eher schwierig beziehungsweise noch nicht ausreichend erforscht zu sein.

Insgesamt werden in der Produktionsbedarfsplanung vor allem unüberwachte Machine Learning Methoden vorgeschlagen und bereits eingesetzt. Sowohl überwachte Machine Learning Ansätze als auch Reinforcement Learning kommen hingegen seltener zum Einsatz.

Eigenfertigungsplanung und -steuerung

Bei der Eigenfertigungsplanung und -steuerung werden die Planvorgaben unter Berücksichtigung des bestehenden Dispositionsspielraums detailliert und die Umsetzung kontrolliert. Der Dispositionsspielraum ergibt sich aus dem frühesten und spätesten möglichen Starttermin der Fertigung. Eine genaue Terminierung ist wichtig, da zu frühe Starttermine hohe Lagerbestände verursachen und zu späte Starttermine hohe Rüstzeiten und mögliche Störungen zur Folge haben können [3]. Die Eigenfertigungsplanung und -steuerung besteht aus den Aufgaben Losgrößenberechnung, Feinterminierung, Ressourcenfeinplanung, Reihenfolgeplanung, Verfügbarkeitsprüfung und Auftragsfreigabe.

In der Eigenfertigungsplanung und -steuerung ist der Einsatz von Machine Learning bereits relativ stark verbreitet. Dies spiegelt sich auch in der Anzahl der Veröffentlichungen wieder. Dabei sticht insbesondere die Feinterminierung hervor. Die Aufgaben der Feinterminierung, also das Festlegen der Anfangs- und Endtermine, sind prädestiniert für den Einsatz von Machine Learning. In diesem Bereich sind häufig viele Daten vorhanden, die sich hervorragend zum Einsatz von Machine Learning Algorithmen zur Analyse eignen.

Baumung und Vomin untersuchen den Einsatz von Machine Learning für die Vorhersage von Fertigungszeiten für komplexe, verschachtelte Produktionsaufträge auf additiven Fertigungsanlagen. Sie entwickeln einen Planungsansatz, der tiefe neuronale Netze nutzt, um Aufträge optimal in verschachtelte Produktionsaufträge zusammen zu führen und um die Bearbeitungsdauer der Produktionsaufträge inklusive Aufwärm- und Abkühlzeit zu bestimmen. Bei der Bildung der Produktionsaufträge werden Fertigungsobjekte aus verschiedenen Aufträgen miteinander so kombiniert, dass sie innerhalb einer vorgegebenen Zeit gefertigt werden können. Mit diesem Ansatz können die Autoren genauere Vorhersagen treffen und Pufferzeiten reduzieren [7].

Ein weiterer Ansatz zur Planung der einzelnen Fertigungstermine wird von Lubosch, Kunath und Winkler vorgeschlagen. Die Autoren zeigen, dass bei kurzen verfügbaren Planungszeiten einfache Planungsregeln eine effiziente Planung erlauben. Im gewählten Anwendungsfall sind bei längeren verfügbaren Planungszeiten zufallsbasierte Ansätze jedoch überlegen. Untersucht wurde hier ein Ansatz, der auf einer Kombination von maschinellem Lernen und einer Monte Carlo Tree Search basiert, wie sie unter anderem in Teslas Autopilot und zur Lösung von Spielen wie Go und Schach zum Einsatz kommt [8]. Der Ansatz hat den großen Vorteil, dass er neben grundlegenden Regeln kein problemspezifisches Wissen benötigt. Es genügt ein einfaches Modell, das die möglichen Aktionen für einen bestimmten Zustand definiert und Zustandsübergänge durchführt. Bei der Terminplanung erlaubt dies, verschiedene Probleme mit demselben Algorithmus zu lösen, wenn ein Modell des Problems erstellt werden kann.

Fremdbezugsplanung und -steuerung

Mit der Fremdbezugsplanung und -steuerung wird festgelegt, welche Teile, Baugruppen und Erzeugnisse in Hinsicht auf Menge und Termin beschafft werden müssen. Dabei sind hohe Lagerbestände zu vermeiden und Konzepte wie Just in Time und Kanban zu berücksichtigen [3]. Unter diese Aufgabe fallen die Bestellrechnung, die Angebotseinholung und -bewertung, die Lieferantenauswahl und die Bestellfreigabe.

In der Fremdbezugsplanung und -steuerung ist der Einsatz von Machine Learning nur sehr schwach verbreitet. Hosseini und Barker untersuchen in diesem Bereich den Einsatz eines Bayes'schen Netzwerks zur Auswahl von Lieferanten. Bayes'sche Netze können Expertenwissen abbilden, indem Zusammenhänge zwischen Ursachen und Wirkungen beschrieben werden. Sie sind leistungsfähige Verfahren zur Risikobewertung und Entscheidungsfindung, wenn Unsicherheit besteht. Das von den Autoren vorgeschlagene Bayes'sche Netzwerk wird für die Bewertung der Leistung von möglichen Lieferanten in Bezug auf primäre, grüne und resiliente Kriterien verwendet, um schließlich den besten Lieferanten auszuwählen. Unter primären Kriterien werden solche wie Kosten, Qualität und Vorlaufzeit verstanden. Grüne Kriterien berücksichtigen Umweltschutzaspekte wie auch einen niedrigen CO₂-Ausstoß. Resilienz Kriterien berücksichtigen die Störanfälligkeit der Lieferanten durch ungeplante Ereignisse wie Streiks oder Naturkatastrophen [9].

Zusammenfassung

Insgesamt lässt sich feststellen, dass Machine Learning in einigen Bereichen der Produktionsplanung und -steuerung großes Optimierungspotenzial bietet. Insbesondere in den Bereichen Durchlaufterminierung und Feinterminierung wurden verschiedene Ansätze in unterschiedlichen Anwendungsfällen positiv evaluiert. Im Bereich der Fremdbezugsplanung und -steuerung sind jedoch bisher nur sehr wenige Veröffentlichungen zu finden.

In den analysierten Quellen wurden viele unterschiedliche Algorithmen des maschinellen Lernens verwendet (Abbildung 3). Beim Supervised Learning wurden vor allem Artificial Neural Networks, Support-Vector-Machines und Bayesian Networks eingesetzt. Im Bereich Unsupervised Learning sticht der K-Means-Algorithmus klar hervor. Im Bereich des Reinforcement Learning wurden Q-Learning-Algorithmen mit Abstand am häufigsten eingesetzt.

Sowohl für produzierende Unternehmen als auch für Softwareanbieter empfiehlt es sich, eigene Optimierungspotenziale in der Produktionsplanung und -steuerung zu erheben, die durch das maschinelle Lernen realisiert werden können. Dabei können die hier dargestellten Erkenntnisse als erste Anhaltspunkte dienen.

Der Artikel basiert auf einer Analyse, die im Seminar „Aktuelle Themen der Wirtschaftsinformatik“ im Masterstudiengang Wirtschaftsinformatik durchgeführt wurde.



Abb. 3: Häufigkeit der verwendeten Algorithmen

Referenzen/References:

[1] T. Wuest, D. Weimer, C. Irgens und K.-D. Thoben, „Machine learning in manufacturing: advantages, challenges, and applications“, *Production & Manufacturing Research*, Jg. 4, Nr. 1, S. 23–45, 2016, doi: 10.1080/21693277.2016.1192517

[2] S. Marsland, *Machine Learning: An Algorithmic Perspective*, 2. Aufl. Hoboken: Chapman and Hall/CRC, 2014

[3] G. Schuh und V. Stich, Hg., „Produktionsplanung und -steuerung“, 4. Aufl. Berlin, Heidelberg: Springer Vieweg, 2012, doi: 10.1007/3-540-33855-1

[4] M. Manns, R. Wallis und J. Deuse, „Automatic Proposal of Assembly Work Plans with a Controlled Natural Language“, *Procedia CIRP*, Jg. 33, S. 345–350, 2015, doi: 10.1016/j.procir.2015.06.079





[5] T. Sobottka, F. Kamhuber, M. Faezrad und W. Sihn, „Potential for Machine Learning in Optimized Production Planning with Hybrid Simulation“, *Procedia Manufacturing*, Jg. 39, S. 1844–1853, 2019, doi: 10.1016/j.promfg.2020.01.254

[6] L. Lingitz, V. Gallina, F. Ansari, D. Gyulai, A. Pfeiffer, W. Sihn, L. Monostori, „Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer“, *Procedia CIRP*, Jg. 72, S. 1051–1056, 2018, doi: 10.1016/j.procir.2018.03.148

[7] W. Baumung und V. V. Fomin, „Predicting production times through machine learning for scheduling additive manufacturing orders in a PPC system“ in *2019 IEEE International Conference of Intelligent Applied Systems on Engineering (ICIASE)*, Fuzhou, China, 26.04.2019 - 29.04.2019, S. 47–50, doi: 10.1109/ICIASE45644.2019.9074152

[8] M. Lubosch, M. Kunath und H. Winkler, „Industrial scheduling with Monte Carlo tree search and machine learning“, *Procedia CIRP*, Jg. 72, S. 1283–1287, 2018, doi: 10.1016/j.procir.2018.03.171

[9] S. Hosseini und K. Barker, „A Bayesian network model for resilience-based supplier selection“, *International Journal of Production Economics*, Jg. 180, S. 68–87, 2016, doi: 10.1016/j.ijpe.2016.07.007

AUTOREN	
	Sophie Sautter M.Sc. Studentin der Wirtschaftsinformatik im Master ssautter@stud.hs-offenburg.de
	Nicolai Haigis M.Sc. Student der Wirtschaftsinformatik im Master nhaigis@stud.hs-offenburg.de
	Manuel Baumert M.Sc. Student der Wirtschaftsinformatik im Master mbaumert@stud.hs-offenburg.de
	Prof. Dr.-Ing Theo Lutz Professur für Wirtschaftsinformatik, Fakultät B+W und IMLA, Betriebliche Informationssysteme theo.lutz@hs-offenburg.de