

Detaillierte Ergebnisse – Teilprojekt

Planung und Steuerung rekonfigurierbarer Prozessketten

ABBILDUNG DER UNTERNEHMENSINTERNNEN LIEFERKETTE

FORSCHUNGSSINTERESSE:

- Welche Produktionsprozesse gibt es innerhalb eines Unternehmens?
- Welche Daten entstehen bei den Produktionsprozessen?
- Inwiefern kann Maschinelles Lernen die Produktionsplanung und -steuerung optimieren?

VORGEHEN:

- Die Wissenschaftler*innen nutzten das Hannoveraner Lieferkettenmodell (HaLiMo), um die unternehmensinterne Lieferkette zu definieren und Einsatzmöglichkeiten digitaler Technologien zu identifizieren.
- Darauf aufbauend entwickelten sie ein logisches Datenmodell, um unternehmensspezifische Datengrundlagen strukturiert zu erfassen und zu analysieren.
- Anschließend sammelten und analysierten die Wissenschaftler*innen Produktionsdaten eines Praxispartners. Diese nutzten sie als Grundlage für ein logisches Datenmodell zur Produktionsplanung und -steuerung.
- Außerdem untersuchten die Wissenschaftler*innen den Einsatz Maschinellen Lernens (ML) zur Prognose von Schlüsselattributen wie Plandurchlaufzeiten.

ERGEBNISSE/ERKENNTNISSE:

- Das auf dem HaLiMo aufbauende logische Datenmodell kann genutzt werden, um strukturiert unternehmensspezifische Datengrundlagen zur Erfüllung der Produktionsplanungs- und -steuerungsaufgaben zu analysieren. Die Analyse kann dazu beitragen, Potenziale für die Erhebung weiterer Datenattribute zu identifizieren sowie den Einsatz von maschinellen Lernverfahren zur Prognose einzelner Kernattribute (z.B. Plandurchlaufzeiten) zu erkennen.
- ML-Verfahren berücksichtigen verschiedene Parameter der Produktionsplanung und -steuerung und lernen aufgrund ihrer gesammelten Erfahrungen. Dadurch wird die Prognose, wieviel Zeit ein Auftrag bis zur Fertigstellung benötigt, immer genauer.

VORHERSAGE VON PLANDURCHLAUZEITEN MITTELS MASCHINELLEM LERNEN (ML)

FORSCHUNGSSINTERESSE:

- Wie können Plandurchlaufzeiten besser kalkuliert werden?
- Welche Einsatzfelder gibt es für Maschinelles Lernen in der Produktion?

VORGEHEN:

- Die Wissenschaftler*innen setzten ML-Modelle ein, um Plandurchlaufzeiten auf Basis vorhandener Produktionsdaten zu kalkulieren. Oftmals basieren Plandurchlaufzeiten auf Schätzungen oder Erfahrungen der Mitarbeiter*innen. Abweichungen im aktuellen Produktionsprozess (z. B. veränderter Auftragsbestand vor den Arbeitsstationen oder Störfälle) berücksichtigen diese nicht hinreichend, wenn sie Plandurchlaufzeiten kalkulieren. Hier kann maschinelles Lernen ansetzen.
- In diesem Zusammenhang untersuchten die Wissenschaftler*innen verschiedene Modelle des maschinellen Lernens und verglichen, welche Faktoren die Prognosegüte der Modelle verbessern.
- Darüber hinaus analysierten die Wissenschaftler*innen die grundsätzlichen Einsatzfelder von ML in der Produktion. Dafür führten die Wissenschaftler*innen eine umfassende Literaturrecherche durch. Sie konzentrierten sich dabei auf die spanende Herstellung von Druckgießformen.

ERGEBNISSE/ERKENNTNISSE:

- Die Wissenschaftler*innen stellten fest, dass die Prognosen der ML-Modelle besser werden, wenn z. B. Daten über Störungsfälle, die Auftragsreihenfolge oder den aktuellen Auftragsbestand einzelner Arbeitsstationen in das Modell einfließen.
- Die Literaturanalyse ergab, dass maschinelles Lernen insbesondere die Leistung, Verfügbarkeit, Qualität und Reaktionsschnelligkeit/Flexibilität spanender Fertigungsprozesse verbessern kann.
- Des Weiteren ermittelten die Wissenschaftler*innen drei Hemmnisse für den Einsatz maschineller Lernverfahren in der Praxis: Zuerst muss überprüft werden, ob ein bestimmtes Problem mit maschinellem Lernen gelöst werden kann. Dann ist zu klären, ob die vorhandene Dateninfrastruktur für maschinelle Lernmodelle vorliegt. Schließlich muss ein Datenanalyst ein passendes Modell auswählen, einsetzen und die Ergebnisse interpretieren.

ABSATZPROGNOSSE MITTELS MASCHINELLEM LERNEN (ML)

FORSCHUNGSSINTERESSE:

- Welches Potenzial hat Maschinelles Lernen bei der Absatzprognose (Wann werden welche Produkte in welcher Menge voraussichtlich nachgefragt)?
- Inwiefern können ML-Methoden traditionelle Zeitserienmodelle bei der Vorhersage von Nachfrage ablösen?
- Welche Möglichkeiten haben kleine und mittlere Unternehmen (KMU), um ML einzusetzen?

VORGEHEN:

- Die Wissenschaftler*innen verglichen die Möglichkeiten von ML mit traditionellen Zeitserienmodellen, bei denen die Prognose ausschließlich auf dem historischen Absatz beruht. Diese Verfahren stoßen jedoch zunehmend an ihre Grenzen: Zum einen sorgen die kürzer werdenden Produktlebenszyklen für kürzere Datenhistorien. Zum anderen gibt es bei sporadisch

nachgefragten Produkten zu wenig Daten. Zusätzlich erzeugen Unsicherheiten am Markt (z. B. durch die Corona-Pandemie) den Bedarf, weitere beschreibende Faktoren in der Prognose zu berücksichtigen.

- Da KMU nicht immer über die notwendigen Kenntnisse zum Umgang mit ML-Methoden verfügen, untersuchten die Wissenschaftler*innen den Einsatz automatisierter Machine Learning Tools (AutoML-Tools), die die Unternehmen nicht selbst programmieren müssen.
- Hierfür testeten sie drei AutoML-Tools in zwei verschiedenen Produktionsumgebungen. Sie untersuchten die Prognose des Bedarfs verschiedener Produktgruppen für einen kurzen Zeithorizont (einen Monat mit 28 Tagen) und einen langen Zeithorizont (ein Jahr mit 52 Wochen).

ERGEBNISSE/ERKENNTNISSE:

- Die Wissenschaftler*innen stellten fest, dass ML-Methoden eine effizientere Möglichkeit zur Erhöhung der Prognosegüte darstellen, da sie besser mit kurzen Datenhistorien, sporadischen Nachfragen und Marktschwankungen umgehen können als traditionelle Zeitserienmodelle.
- Der Einsatz von AutoML-Tools kann KMUs ermöglichen, ML in die Absatzprognose zu integrieren, ohne umfangreiche Programmierkenntnisse zu benötigen.
- Die Analyse der drei Auto-ML-Tools ergab, dass die Prognosegüte abhängig ist von der Software, den Eingabedaten und dem Nachfrageverhalten. AutoML zeigt insbesondere bei der kurzfristigen Prognose gute Ergebnisse. Bei langfristigen Prognosen bedarf es jedoch weiterer beschreibender Merkmale zur Verbesserung der Modellgüte.
- Dennoch stellt AutoML vor allem für das Prototyping und den Abgleich der Daten mit dem Geschäftsverständnis ein sehr gutes Einsatzfeld dar. So lassen sich präzisere datengestützte Prognosemodelle entwickeln.
- ML und AutoML haben jedoch den Nachteil, dass die Modelle im Vergleich zu statistischen Modellen komplexer sind und somit mehr Rechenleistung benötigen. Außerdem sind sie schwieriger nachzuvollziehen.

STATUS QUO ZUM EINSATZ VON KÜNSTLICHER INTELLIGENZ IN DER PRODUKTION

FORSCHUNGSSINTERESSE:

Inwiefern setzen Produktionsunternehmen Künstliche Intelligenz ein?

VORGEHEN:

Die Wissenschaftler*innen führten Experteninterviews mit 30 Produktionsunternehmen durch, um den Status Quo zum Einsatz von Künstlicher Intelligenz (KI) in der Produktion zu erheben. Diese Unternehmen verfügen über eine eigene Fertigung, z. B. aus den Bereichen Luft- und Raumfahrt oder Maschinen- und Anlagenbau.

ERGEBNISSE/ERKENNTNISSE:

- Die Auswertung der Interviews ergab, dass die Mehrheit der produzierenden Unternehmen bisher noch keine KI in der Arbeitsvorbereitung sowie zur Prozess- und Zustandsüberwachung einsetzen.
- Die Ursachen, weshalb die Unternehmen noch keine KI nutzen, sind ganz unterschiedlich: Zum einen ist vielen Betrieben noch nicht klar, welches Potenzial KI für die Produktion hat. Zum anderen werden oftmals ältere Maschinen eingesetzt, bei denen die Prozessdaten nicht so einfach akquiriert werden können. Größere Unternehmen können sich hierfür Mitarbeiter*innen leisten, die entsprechende Schnittstellen entwickeln oder ein Retro-Fit durchführen, um Daten aus der Maschinensteuerung oder externer Sensoren zu akquirieren. Dies ist mit zusätzlichen Kosten verbunden. Kleinere Betriebe haben dafür keine Ressourcen. Darüber hinaus stellt es ein Problem dar, die Daten unterschiedlicher Maschinen zusammenzuführen, zu speichern und auszuwerten. Dabei spielen auch die Rückverfolgbarkeit von Bauteilen und die Verknüpfung mit den Prozessdaten eine wichtige Rolle.

ML-BASIERTE ABSATZPROGNOSSE AM ANWENDUNGSBEISPIEL DER CHEMIEINDUSTRIE

FORSCHUNGSSINTERESSE:

Sind Methoden des Maschinellen Lernen besser geeignet als klassische statistische Verfahren, um den Absatz eines Chemieunternehmens zu prognostizieren?

VORGEHEN:

- Die Wissenschaftler*innen untersuchten Methoden des Maschinellen Lernens und analysierten auch das Potenzial öffentlich verfügbarer Daten (z. B. Konjunkturdaten und Branchenindizes) zur Annäherung an die möglichen langfristigen Bedarfe der Kund*innen.
- Sie verglichen die Ergebnisse mit klassischen statistischen Verfahren.

ERGEBNISSE/ERKENNTNISSE:

- Die Ergebnisse zeigen, dass ML-Modelle durch die Einbeziehung externer Daten insbesondere bei Strukturbrüchen gute Prognosen über die Absatzverläufe erstellen können. Strukturbrüche sind durch einen plötzlichen Einbruch der „gewohnten“ Nachfrage gekennzeichnet, wie es z. B. durch die Corona-Pandemie oder den russischen Angriffskrieg auf die Ukraine der Fall war.
- Der Aufbereitungsaufwand solcher Modelle ist jedoch im Vergleich zu statistischen Verfahren wesentlich höher. Außerdem kann sich die Datenverfügbarkeit oder die Qualität der externen Daten verändern. Dennoch war der Zugewinn der Prognosegenauigkeit im untersuchten Fallbeispiel teils erheblich und bot sich insbesondere bei einem sich stark verändernden externen Umfeld an, um den Nachfrageschock präziser abzubilden.

ML-BASIERTES RISIKOMANAGEMENT IN LIEFERKETTEN

FORSCHUNGSSINTERESSE:

- Inwiefern kann Maschinelles Lernen das Risikomanagement in Lieferketten (Supply Chain Management, SCM) verbessern?
- Welche Vorteile hat eine Kreislaufwirtschaft für Lieferketten?
- Welche Datenflüsse gibt es entlang einer Lieferkette?

VORGEHEN:

- Die Wissenschaftler*innen führten Literaturrecherche zu den Potenzialen von ML und Big Data im strategischen Supply-Chain-Risikomanagement durch.
- Zudem untersuchten sie, wie das Konzept der Kreislaufwirtschaft in Lieferketten integriert werden kann, um den Lebenszyklus von Produkten zu verlängern und Ressourcen zu schonen.

- Als Beispiel analysierten sie die Lieferkette in der deutschen Windenergiebranche, da hierfür Daten des Marktstammdatenregisters der Bundesnetzagentur vorlagen. Für die Druckgussindustrie waren keine Daten öffentlich verfügbar.
- Daraufhin entwickelten die Wissenschaftler*innen ein Konzept zur Integration der Kreislaufwirtschaft in das SCM.
- Des Weiteren analysierten die Wissenschaftler*innen die Lieferketten innerhalb der Windenergiebranche, die mit der Herstellung einer Windturbine und insbesondere von Rotorblättern betraut sind. Ziel war es, die Lieferkette und deren Datenflüsse besser zu verstehen.
- Um ein tiefergehendes Verständnis der Lieferketten zu gewinnen, führten die Wissenschaftler*innen Gespräche mit unterschiedlichen Stakeholdern (z. B. Zulieferern, Herstellern von Windenergieanlagen, Betreibern, Rückbauunternehmen). Zudem analysierten sie die öffentlich verfügbaren Daten.

ERGEBNISSE/ERKENNTNISSE:

- Die Forschung zeigte, dass ML und Big Data das Supply-Chain-Risikomanagement erheblich verbessern und zur Integration der Kreislaufwirtschaft beitragen können.
- Das entwickelte Konzept zur Kreislaufwirtschaft im SCM umfasst die gesamte Lieferkette, von der Produktion bis zur Entsorgung, und hebt die Bedeutung der Digitalisierung für den Datenaustausch zwischen Unternehmen hervor.
- Die Untersuchung der Windenergiebranche demonstrierte, wie erste Schritte zur Implementierung dieser Konzepte in Lieferketten aussehen könnten.
- Die Gespräche mit den Stakeholdern und die Analyse der öffentlich verfügbaren Daten zeigte, dass Daten zu weiteren Nutzungsphasen einer Windenergieanlage oder deren Komponenten (z. B. Rotorblättern) weitestgehend fehlen. Dennoch lassen sich Prognosen zu Bedarfen ableiten, die eine langfristige Kapazitätsplanung verschiedener Stakeholder (z. B. Wiederaufbereitungs-, Reparatur- und Recyclingunternehmen) ermöglichen. Die Wissenschaftler*innen begannen damit, Prognosemethoden über die zu erwartenden Mengen zu erstellen. Für die nationale Recyclingbranche haben sie den Vorgang bereits abgeschlossen.