

» Vorgehenskonzept für Machine Learning für die intelligente Fabrik

Digitalisierung in der Fabrik umsetzen

Hochlohnstandorte sind seit Jahren ausgesprochen herausgefordert. Der starke Schweizer Franken und die hohe Volatilität in verschiedenen Branchen verstärken den Fokus auf die Produktionskosten in der Schweiz umso mehr. Die umfassendere Nutzung der Digitalisierung wird als eine entscheidende Antwort auf diese Veränderungen gesehen. Im Produktionsumfeld stellt sich vermehrt die Frage, wie eine Produktion das Lernen aus Daten im Sinne einer intelligenten Fabrik umsetzt.

» Roman Hänggi¹, Curdin Wick², Guido Schuster³, Lukas Budde⁴

Im Rahmen von zwei Innosuisse Projekten mit mehreren Produktionsbetrieben, Maschinenherstellern, Software Herstellern und zwei Forschungsinstitutionen (Hochschule für Technik Rapperswil (HSR), Universität St. Gallen (HSG)) haben wir uns vertieft mit der Thematik beschäftigt, wie man aus Daten lernen kann, um die Fabrik effizienter zu machen. Zusätzlich interessierte uns die Fragestellung, wie ein Vorgehenskonzept zur Umsetzung aussehen könnte. Viele der hier dargestellten Erkenntnisse sind anhand von verschiedenen Produktionsprozessen (u.a. Spritzgießen) erarbeitet worden. Verschiedenste Verarbeiter und Maschinenhersteller haben dazu einen signifikanten Beitrag geleistet.

Durch die Breite der involvierten Firmen konnten verschiedene Use Cases angegangen und daraus ein Vorgehen (Bild 1) entwickelt werden, das mehrfach hinterfragt und optimiert wurde.

Das Vorgehenskonzept ist in 5 Phasen unterteilt. Festlegen des Use Cases ist der erste wichtige Schritt. Zielorientiertes Vorgehen ist entscheidend, um den Aufwand der Datensammlung zu fokussieren. Zentral im Vorgehenskonzept ist die Erarbei-

¹ Prof. Dr. Roman Hänggi, Produktionsmanagement & Industrie 4.0, HSR

² Curdin Wick, Wissenschaftlicher Mitarbeiter am Institut für Werkstofftechnik und Kunststoffverarbeitung (IWK), HSR

³ Prof. Dr. Guido Schuster, Elektrotechnik & Machine Learning, HSR

⁴ Dr. Lukas Budde, Oberassistent Institut für Technologiemanagement (ITEM), Universität St. Gallen (HSG)

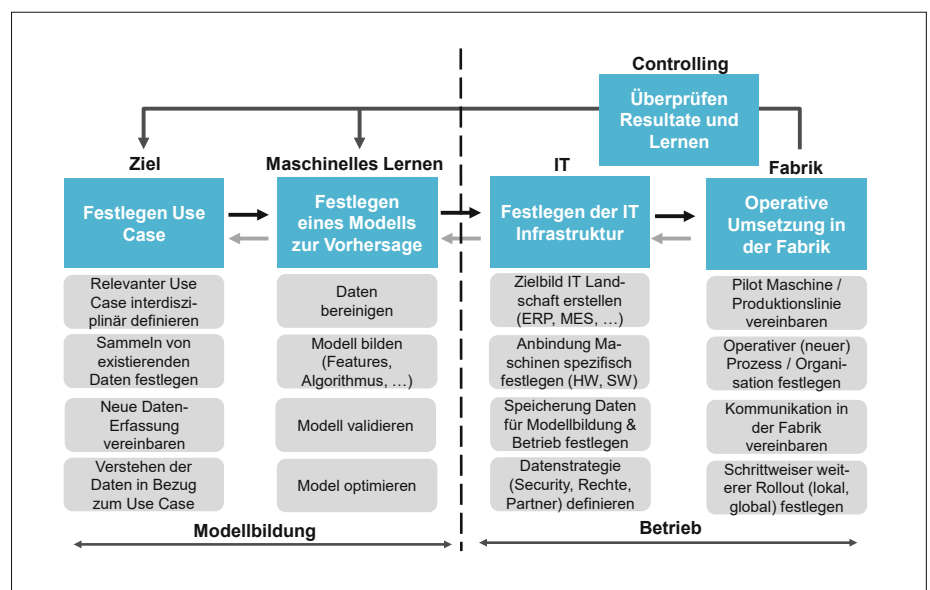


Bild 1: Vorgehenskonzept des maschinellen Lernens für die Fabrik.

tung des Modells zur Vorhersage mit Methoden des maschinellen Lernens. Auf diesem Modell basiert die ganze Optimierung des festgelegten Use Case. Erst nach der Validierung des Modells sollte die IT-Umsetzung in Angriff genommen werden. Nach dieser eher technischen Phase sollte dann die Umsetzung in der Fabrik mit den Mitarbeitern angegangen werden. Der abschliessende Schritt des Feed-back Loop, um aus den umgesetzten Anwendungen zu lernen, ist sehr wichtig. So können allenfalls Korrekturmassnahmen für die weiteren Umsetzungen eingeleitet werden, aber auch, um die Resultate zu messen und transparent zu machen. Erfolgreiche Umsetzungen in der Breite hängen stark auch von ersten positiven Resultaten ab. Dieses Vorgehenskonzept zeichnet sich durch Iteration mit klaren Phasen aus. Es hat sich in der Praxis gezeigt, dass sich die einzelnen Schritte gegenseitig beeinflus-

sen können und auch sollen. Ebenfalls sind Rückschritte und Änderungen von bereits festgelegtem durchaus möglich und zielführend. Mit dem Start des Prozesses «Lernen aus Daten» beschreitet jede Firma ihren spezifischen Weg, der immer viel Neues und Überraschendes zu Tage fördert. Dieser Prozess ist auch immer einzigartig und die konkrete Umsetzung kann nicht von Fabrik zu Fabrik kopiert werden. Zu unterschiedlich ist meistens die Ausgangssituation. Die Art des Fertigungsprozesses, das Fabrikat der Maschinenhersteller, das Alter der Maschinen, die IT-Infrastruktur, aber auch organisatorische Aspekte haben grossen Einfluss auf die Ausgestaltung und die Qualität des Lernens aus Daten. Am Ende hängt viel davon ab, ob die Situation es erlaubt, eine umfassende Anzahl und qualitativ gute Daten zu erfassen. Diese gilt es dann mit tiefem Verständnis der Firma und der

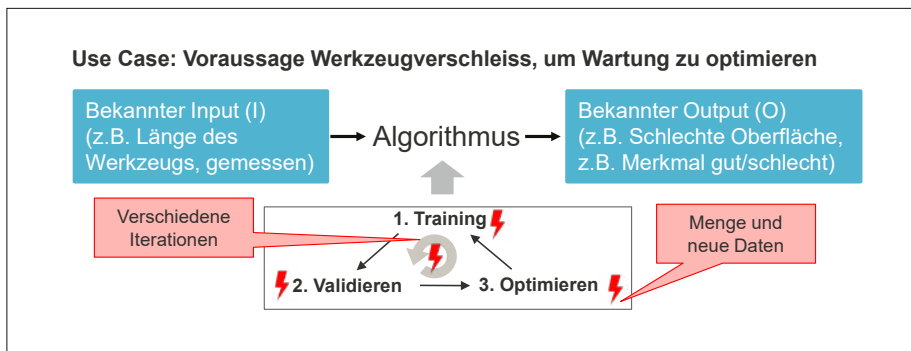


Bild 2: Herausforderungen zur Festlegung des Algorithmus des maschinellen Lernens für die Fabrik.

Technologie zu koppeln, um daraus mit mathematischen Modellen Ansätze zur Optimierung zu formulieren.

Die Basis für das erfolgreiche Beschreiten dieses Wegs hängt stark mit der Kultur im Unternehmen zusammen. Der Produktionsprozess wird datenbasiert nachvollzogen. Diese erhöhte Transparenz muss für die Organisation motivierend wirken und nicht dazu führen, dass Transparenz als Gefahr gesehen wird. In der Praxis führt dies oft zu Herausforderungen bereits beim Start der Initiative. Das strukturierte Erfassen, Verstehen und Bereinigen der Daten, bezogen auf einen spezifischen Use Case, fördert oft bereits verschiedene Optimierungen an den Tag. Häufig ist zu diesem Zeitpunkt noch kein mathematisches Modell zum Lernen entstanden, sondern man diskutiert offen über die vorhandenen oder neu erarbeiteten Daten. Dieses Verstehen der Daten in Bezug auf

den Use Case ist für die weitere Modellbildung wichtig. Erste Verschwendungen wie auch organisatorische Defizite werden so schon früh im Prozess transparent, können angegangen und erste Resultate realisiert werden. Ebenfalls sieht man auch sofort, ob die Daten eine genügende Qualität für die nächsten Schritte aufweisen. Wenn diese neuen Erkenntnisse nicht als Chance empfunden werden, wird es schwierig auf dem weiteren Weg 'zum Lernen aus Daten' und das Projekt kommt schon früh ins Stocken.

Neben der Verfügbarkeit von umfassenden Daten, hängt der Erfolg stark von der Akzeptanz im Unternehmen ab. Es hat sich gezeigt, dass dieser Weg ein breites interdisziplinäres Team schon beim Start erfordert. Neben den verschiedenen Fachdisziplinen wie Produktion, IT, Entwicklung, soll das Team auch Erfahrung mit den bestehenden Prozessen und Maschinen auf-

weisen. Zusätzlich sind weitere Expertisen in den Bereichen maschinelles Lernen, Programmierung wie auch Cloud Computing oder Datenmodelle notwendig. Diese müssen nicht notwendigerweise in der Firma vorhanden sein. Externe Unterstützung und Partnerschaften können hier gut helfen.

Die beiden Forschungsprojekten haben neben dem Vorgehenskonzept für das maschinelle Lernen in der Fabrik einzelne Punkte in der Umsetzung geklärt.

Fokus auf relevante Use Cases

Zentral bei jeder Initiative ist der Use Case. Es hat sich gezeigt, dass es für die intelligente Fabrik viele Use Cases gibt und auch umfassend in der Literatur diskutiert werden [1]. Grob kann man die Use Cases entlang der Kernprozesse Planung, Ausführung und Unterstützung einteilen. So macht es Sinn, sich zu Beginn eines Projektes zu überlegen, wo der spezifische Use Case sich befindet. Dies ist entscheidend, um das Projekt richtig aufzusetzen und die richtigen Teammitglieder ins Projektteam zu berufen. Ebenfalls hat sich in der Praxis gezeigt, dass die Firmen sehr genau ihre verschiedenen möglichen Use Cases kennen. Jedoch sind das Verständnis und die Interessenlage in der Organisation oft sehr divergierend. So ist es wichtig, einen strukturierten und interdisziplinären

nären Prozess auf unterschiedlichen Hierarchiestufen zu durchlaufen, um die Prioritäten der möglichen Use Cases herauszuarbeiten. Erst der gemeinsam festgelegte Use Case kann genug Energie entwickeln, um den nicht immer einfachen Weg des Lernens aus Daten für die Fabrik zu beschreiten. Falls diese bewusste Vereinbarung nicht existiert, sieht man oft, dass bei der ersten grösseren Hürde das Projekt abgebrochen wird oder die finanziellen und personellen Ressourcen nicht mehr zur Verfügung gestellt werden.

Datensammeln zur Modellbildung

Nach dem Festlegen des Use Cases ist das Sammeln der Daten ein herausfordernder Prozess. Es gilt die vorhandenen Daten zu sichten, mit allenfalls neuen und noch zu generierenden Daten zu erweitern und umfassend zu verstehen. In diesem Prozess gilt es, den zielführenden Produktionsprozess und relevante Produktionsaufträge festzulegen. Gerade beim Spritzgiessen sind Ausgangsmaterial und eingesetztes Werkzeug weitere zentrale Elemente. Oft fehlen jedoch wichtige Daten, die es dann spezifisch für das Projekt noch zu erfassen gilt. Das Zusammenführen der verschiedenen Datensätze bringt neue Herausforderungen mit sich. Oft sind die Daten in verschiedenen IT-Systemen, Maschinensteuerungen oder Datenbanken verteilt abgelegt. Diese Daten sind dann häufig auch noch in der Verantwortung verschiedenster Organisationseinheiten. Neben der rein technischen Zusammenführung und dem Speichern der Daten, müssen so oft auch noch organisatorische Hürden genommen werden.

In vielen Projekten wird in dieser Phase oft die IT-Landschaft hinterfragt. Es ist richtig, dass der Prozess des Zusammenführens der relevanten Daten bei der ersten Initiative aufwändig und ineffizient sein kann. Jedoch ist es in diesem Stadium des Projektes noch zu früh, die IT-Landschaft mit grösseren Investitionen anzupassen. Oft kennt man jetzt noch nicht alle Bedürfnisse zur zukünftigen IT-Landschaft für die Smarte Fabrik. Somit ist es zielführend, sich in dieser Phase mit vielen temporären und oft auch aufwändigen Prozessen zur Datensammlung und Speicherung zu behelfen.

Maschinelles Lernen braucht viele relevante Daten

Der Ausgangspunkt des maschinellen Lernens baut auf der Basis von Daten einen Algorithmus, den man dann mit neuen Daten überprüft und allenfalls anpasst, bis das mathematische Modell genügend stabil ist. Das maschinelle Lernen hat verschiedenen Ansätze. Für die Smarte Fabrik ist das sogenannte überwachte Lernen (Supervised Learning) oft eine zielführende Methode. Dabei lernt ein Algorithmus aus gegebenen und bekannten Input- und Output-Paaren eine Funktion, die das Ergebnis eines neuen Inputs auf Basis des Algorithmus vorhersagen soll. Dieser Prozess des maschinellen Lernens nutzt spezifische Software (z. B. Python, Matlab) und verschiedenste mathematische Methoden (z. B. neuronale Netze, Regression, Klassifikation).

Der Prozess zum Festlegen des Algorithmus hängt direkt mit der Menge und Qualität der vorhandenen Daten zusammen. Zuerst werden viele Datensätze gebraucht, um den Algorithmus lernen zu lassen. Das trainierte Modell muss dann mit neuen Datensät-

zen validiert und allenfalls weiter optimiert werden. Die Trainingsdaten wie auch die Validierungsdaten müssen unterschiedlich sein. Jede allfällige Optimierung braucht oft auch wieder neue Daten, was zum Erfassen von neuen Daten mit zusätzlichen Produktionsaufträgen führen kann (Bild 2). Diese Optimierungsschlaufen sind in einem Produktionsumfeld aufgrund der hohen Komplexität (verschiedene Maschinen, verschiedene Produktionsaufträge, ...) aufwändig und zeitintensiv. Der hohe Druck auf Produktivität in vielen Werken lässt es oft nicht zu, umfassende Aufwendungen zum Sammeln von Zusatzdaten für das «Machine Learning Projekt» zu integrieren. Die beiden Forschungsprojekte haben für spezifische Use Cases im Bereich der Qualitätsmessung [2] und präventiver Wartung interessante und zukunftsfähige Algorithmen und Ansätze bereits aufzeigen können. Die weitere Forschung fokussiert sich auf die Generalisierung der Ansätze über mehrere Arten von Produkten und Maschinen.

Die Umsetzung muss zielführend angegangen werden

Das Vorhandensein eines Algorithmus für einen spezifischen Use Case steht erstmals im Zentrum eines Prozesses zum Lernen aus Daten für die Fabrik von morgen. Jedoch zeigt sich schnell, dass in der operativen Umsetzung die temporäre und

aufwändige Datensammlung und Abspeicherung nicht zielführend sein kann. Hohe personelle Aufwendungen, aber auch Sicherheitsaspekte und eine effiziente Skalierung über mehrere Produktionslinien und Werke, wie auch für verschiedenste Use Cases, verlangen eine umfassende Auseinandersetzung mit der langfristigen IT-Landschaft. Die Forschung hat bis heute folgende erste Themengebiete für die Smarte Fabrik aufgezeigt und verschiedenste Ansätze sind zurzeit in der Evaluation. Es ist heute noch zu früh, die Vor-/Nachteile und Inhalte der diversen Themengebiete und Ansätze umfassend zu diskutieren.

- Zielbild IT-Landschaft: MES, ERP, Q-System, Maschinensteuerung, Data Lake für Business Intelligenz / Maschinelles Lernen, ...
- Anbindung der Maschine: Direkt, maschinenspezifische Datenlogger, generelle IoT Box, ...
- Schnittstellen: Maschinenspezifische Anbindung, OPC UA-Standards, andere Standards, ...
- Notwendige Updates – Raten der Signale: Entwicklung neuer Algorithmen, Umsetzen in der Produktion, Darstellung Produktionsdashboard, ...
- Speicherung der Daten für Modellbildung und Betrieb: Steuerung, IoT Box, lokaler Server, Cloud, ...
- Datenstrategie: Zugriffsrechte, Datensicherheit, Partnerschaften, ...

Die Forschungsprojekte zeigen eine hohe Komplexität bei der Festlegung der IT-Landschaft. Wir sind überzeugt, dass ein langfristiges Zielbild nötig ist, jedoch nur eine schrittweise Umsetzung eine ressourcenoptimierte Umsetzung zulässt. Diese langfristige IT-Landschaft hängt jedoch auch stark vom strategischen Ansatz für die Smarte Fabrik oder für die gesamte Produktion zusammen. Fragestellungen der Skalierung des Lernens ist zentral. Die Frage, ob Daten über Abteilungen, Werke oder sogar über ein globales Produktionsnetzwerk geteilt und gemeinsam genutzt werden sollen, ist zu beantworten.

Literatur

[1] Classen, Moritz; Blum, Christoph; Budde, Lukas; Hänggi, Roman & Friedli, Thomas (2018) Digitalisierung à la carte – Individuelle Auswahl von Use-Cases nach strategischen Prioritäten. ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb, 113 (12). 850-854. ISSN 0947-0085

[2] F. Ehrig and G. Schuster, «Machine Learning zur Erkennung von Veränderungen beim Spritzgiessprozess», VDI-Jahrestagung Spritzgiessen, Baden-Baden, 19./20.02.2019

Kontakt

Hochschule für Technik (HSR)
Prof. Dr. Roman Hänggi
Oberseestrasse 10, CH-8640 Rapperswil
+41 55 222 46 03
roman.haenggi@hsr.ch, www.hsr.ch