

Wie die KI in die Praxis kommt

ML soll in den zunehmend komplexen und veränderlichen Fabriken Prozessoptimierungen ermöglichen. Doch wie gelangen die KI-Verfahren vom Reißbrett in die Praxis? Ein Vorgehensmodell beschreibt den Weg.

VON DR. JULIUS PFROMMER UND CHRISTIAN FREY

MODERNE Produktionsanlagen sind oft so komplex, dass qualitätsrelevante Zusammenhänge durch klassische Modellbildung nur unvollständig erfasst werden können. Viele Optimierungspotenziale lassen sich deshalb nur datengestützt mit Methoden des maschinellen Lernens (ML) erschließen. ML kommt deshalb zunehmend und mit großem Erfolg zum Einsatz, um etwa die Produktqualität zu steigern, den Ressourceneinsatz zu reduzieren oder ungeplante Maschinenausfälle durch vorausschauende Wartung zu vermeiden. Die wirksame Umsetzung in der industriellen Produktion, über reine Pilotprojekte hinaus für die Anwendung im dauerhaften Betrieb, ist jedoch herausfordernd.

Das Potential und die Krux von ML

Die Erfahrungen verschiedener Fraunhofer-Institute zeigen sowohl in der Prozess- als auch in der Stückgut-produzierenden Industrie ein großes Potential für die An-

wendung von ML-Methoden. Für die Umsetzung fehlt es derzeit jedoch an Experten, die vertiefte Kenntnisse sowohl in der Produktions- und Automatisierungstechnik als auch in ML mitbringen. Es hat sich zudem gezeigt, dass eine wirksame Umsetzung von ML-Projekten bis zum produktiven langjährigen Einsatz im Betrieb eine professionelle ingenieurtechnische Herangehensweise in großen und interdisziplinären Projektteams erfordert. Das dafür notwendige Vorgehen unterscheidet sich von Forschungsprojekten, in denen nur prototypische Entwicklungen auf der Agenda stehen.

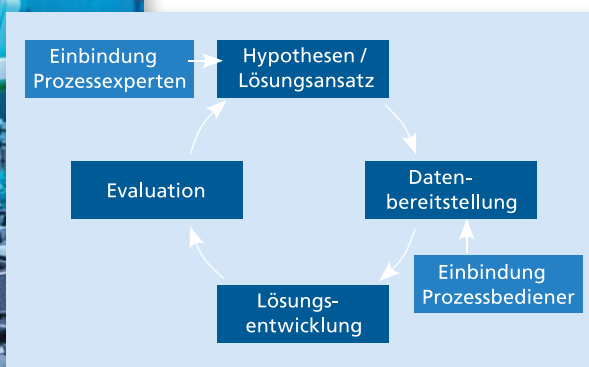

Das Leitprojekt

Im Fraunhofer-Leitprojekt „Machine Learning for Production“ (ML4P) wurde unter Leitung des Fraunhofer IOSB ein toolgestütztes Vorgehensmodell für die Umsetzung von ML in der Produktion entwickelt. Der in ML4P und weiteren Projekten verfolgte Ansatz des KI-Engi-

neerings [1] orientiert sich in vieler Hinsicht am Systems Engineering.

Die breiten Erfahrungen der beteiligten Institute ermöglichen es, grundlegende Methoden zu detaillieren sowie die dazu passende, durchgängige Kette interoperabler Softwarelösungen zu entwickeln. Diese Softwaretools dienen dazu, systematisch das relevante Wissen und die Daten einer Produktionsanlage zu erfassen, zu formalisieren und für die Nutzung des ML-Methodenspektrums aufzubereiten. Weiterhin können sie vorhandene Optimierungspotenziale aufspüren und bewerten, bestgeeignete ML-Verfahren anwendungsspezifisch auswählen und diese nutzbringend einsetzen.

Das veröffentlichte Vorgehensmodell [2] beschreibt im Kern eine Abfolge von dedizierten Phasen für die Durchführung von ML-Projekten und ermöglicht die Skalierung auch auf große Projektteams durch vorausschauende Planung, Quantifizierung des Fortschritts und der Festlegung von definierten Zwischenergebnissen mit klaren Schnittstellen zwi-



Iterative Vorgehensweise für den Proof of Concept.

schen Verantwortlichkeiten. Im Gegensatz zu bekannten Vorgehensmodellen aus dem klassischen Data Mining, wie Crisp-DM, wird dabei auf die speziellen Anforderungen der industriellen Produktion eingegangen.

Wie kommt Machine Learning aus der Modellfabrik in den industriellen Produktions-Alltag? Hier ein Vorgehensmodell.

Bilder: Fraunhofer IOSB

Das Machine Learning Pipeline-Diagramm

Machine Learning orientiert sich typischerweise an einer datenzentrierten Verarbeitungskette: Von der Entstehung, der Aufbereitung und fragestellungsbezogenen Modellbildung, der Ableitung von Entscheidungen bis hin zur Aktorik/Einflussnahme auf den Prozess selbst.

Das „Machine Learning Pipeline-Diagramm“ bildet die Basis für das Vorgehensmodell und findet Verwendung in allen Phasen des Projektes - von der Zieldefinition bis hin zum kontinuierlichen und nachhaltigen Betrieb in der Produktion. Es verbindet zum einen alle wichtigen technologischen Aspekte der ML-basierten Lösung und beschreibt notwendige Schnittstellen, zum anderen dient es der Kommunikation zwischen den Stakeholdern, vom den Prozessexperten bis hin zur Management-Ebene.

Ofentemperatur: Parameteroptimierung für sich ändernde Eingangsmaterialien

Im Beispiel wird die optimale Anpassung von Prozessparametern (Ofentemperatur – siehe Grafik auf der Folgeseite) an sich ändernde Eigenschaften in den Eingangsmaterialien betrachtet. Dazu werden auf der linken Seite des Pipeline-Diagramms die notwendigen Daten erhoben. Dies sind die Qualitätsmessungen aus dem Labor, die kontinuierlich gemessene Ofentemperatur und die Materialeigenschaften, welche aus einer zentralen Datenbank abgerufen werden. Die Datenströme sind farblich entsprechend der Häufigkeit der Übertragung markiert. Die Datenbank wird genutzt, um die heterogenen Datenströme zusammenzuführen und gemeinsam zu betrachten.

Stehen ausreichend historische Daten zur Verfügung, kann ein datengetriebenes ML-Vorhersagemodell für die Produktqualität erstellt werden. Das Prozessmodell findet Verwendung in einem weiteren Modul zur Optimierung der Ofentemperatur unter Einbezug der aktuellen Materialeigenschaften. Die Ergebnisse der Optimierung werden visualisiert und vom Prozessbediener am Ofen eingestellt.

Einige Schritte in der Verarbeitungskette können manuell ausgeführt werden. Dies ist durch ein Personen-Icon gekennzeichnet. Entscheidungen mit Auswirkung auf den Prozess sind durch einen Stern markiert.

Die Phasen des Vorgehensmodells

Das im Fraunhofer-Leitprojekt ML4P entwickelte Vorgehensmodell gliedert sich in sechs abgegrenzte Phasen. Jede Phase definiert eine Reihe von spezifischen Ergebnissen, die den Projektfortschritt transparent aufzeigen, und endet mit einem Meilenstein, bei dem die Ergebnisse begutachtet werden und die folgende Phase geplant wird.

1. Phase:

Zielsetzung und Lösungsansatz

In der ersten Phase werden die Wirkzusammenhänge in einem Team aus ML- und Prozessexperten gemeinsam analysiert und auf Basis definierter Projektziele ein ML-basierter Lösungsansatz, technische Maßnahmen zur Zielerreichung und eine erste Kosten-/Nutzen-Schätzung abgeleitet. Zentrale Elemente in dieser Phase sind das ML-Pipeline-Diagramm sowie das Prozessdossier. Für die Erarbeitung dieser Artefakte ist es notwendig, ein gemeinsames Verständnis zum technischen Prozess und dessen Optimierungspotential zu Erlangen. Abgeleitet davon werden für die Zielerreichung notwendige technische Maßnahmen sowie ein erstes ML-Lösungskonzept erarbeitet.

2. Phase: Proof of Concept

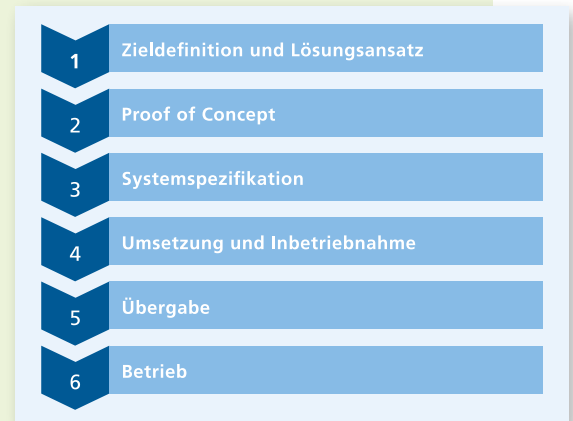
Beim Proof of Concept (PoC) wird ein Nachweis darüber geführt, ob die gesetzten Ziele des Projektes erreicht werden können. Die Basis hierfür stellen die in Phase 1 erarbeiteten Hypothesen zur Zielerreichung und das daraus abgeleitete erste ML-Lösungskonzept dar. Der PoC dient alleine der Entwicklung von Methoden und der Feststellung der Erfüllbarkeit der Projektziele. Er stellt also nicht das endgültige Entwicklungsergebnis dar. In der Praxis wird ein PoC als iterativer Prozess umgesetzt - in Verbindung mit exemplarisch aus dem Prozess erhobenen Daten werden die ML-Konzepte in Bezug auf die gesetzten Ziele evaluiert, optimiert und gegebenenfalls modifiziert. Die Evaluierung der erreichten Zwischenergebnisse wird im Team aus Prozess- und ML-Experten durchgeführt und bietet dadurch die Möglichkeit, Designprobleme frühzeitig zu erkennen, etwaige Modifikationen an der Zielstellung vorzunehmen oder gar einen Projektabbruch herbeizuführen.

3. Phase: Systemspezifikation

Der PoC wird den Anforderungen an den Produktionsalltag noch nicht genügen und kann noch manuelle Schritte in der Datenaufnahme und -verarbeitung enthalten. Weiterhin bedarf es im PoC meist einer dedizierten Betreuung der Systeme durch ML-Experten. In Phase 3 wird aus dem PoC ein System für den dauerhaften Einsatz in der Fertigung abgeleitet. Die Spezifikation muss alle für eine Umsetzung notwendigen Aspekte umfassen, die für die Implementierung des ML-Lösungskonzeptes notwendig sind – die Vorgehensweise zur informationstechnischen Integration, die etwaig notwendigen Modifikationen an den Maschinen und Anlagen, das Bedienkonzept, sowie das Wartungskonzept für den Betrieb. Zudem wird eine detaillierte Kostenabschätzung für die Umsetzung der Systemlösung erarbeitet, die eine Abschätzung der direkten technischen und organisatorischen sowie möglicher indizierter Kosten für die Umsetzung und den Betrieb im Verhältnis zum erwarteten Nutzen als Basis für eine gegebenenfalls auch gestaffelte Investitionsentscheidung ermöglicht.

4. Phase: Umsetzung, Integration und Inbetriebnahme

In dieser Phase wird anhand der Systemspezifikation ein lauffähiges System für den dauerhaften Produktiveinsatz umgesetzt und in Betrieb genommen. Sie muss nicht unbedingt von den ML-Experten aus Phase 1 bis 3 (mit-)umgesetzt werden – unter der Voraussetzung, dass die Systemspezifikation und Entwicklungsartefakte aus dem PoC ausreichend detailliert für eine Vergabe an weitere Dienstleister oder Entwicklungsgruppen sind. In großen Realisierungsprojekten findet häufig eine >



Die sechs Phasen des ML4P-Vorgehensmodells.



Anwender-Workshop

READY-TO-USE IOT – DIE CHANCEN DER DIGITALISIERUNG JETZT NUTZEN!

29.04.2021 • 10:00 - 17:00 Uhr

WORKSHOPZIEL

Mit besseren Lösungen die Produktion steigern und das Unternehmen wettbewerbsfähiger machen – das sind die Herausforderungen der Maschinen- und Anlagenbauer.

Deshalb zeigt Ihnen unser Spezialist, Tobias Hennemann, wie sich die Chancen der fortschreitenden Digitalisierung im Maschinen- und Anlagebau konkret ergreifen lassen. In praktischen Übungen erleben Sie die einfache Umsetzung von IIoT-Anwendungen mit den passenden Hardware-Komponenten und Cloud-Lösungen.

AGENDA

- Die Chancen der fortschreitenden Digitalisierung im Maschinenbau
- Der Weg der Daten vom Sensor in die Cloud
- Der einfache Einstieg ins IIoT mit den passenden Komponenten

TEILNEHMERINFORMATIONEN:

Teilnahmegebühr Workshop:
EUR 75,00 netto + MwSt.

Teilnahmegebühr Workshop inkl. Starterkit:
EUR 399,00 netto + MwSt.

Die Teilnehmerzahl ist auf max. 10 Personen begrenzt. Ein eigenes Windows Notebook mit Administrationsrechten ist erforderlich. In der Teilnahmegebühr sind zusätzlich enthalten: Tagungsunterlagen, Teilnahmezertifikat, ein Mittagessen und Erfrischungen während der Pause.

DETAILLIERTE INFORMATIONEN UND ANMELDUNG ZUM WORKSHOP:

wieland.automatisierungstreff.com



gestaffelte Umsetzung und Inbetriebnahme statt. Dies kann sich am physischen Layout der Anlage, der Reihenfolge von Prozessschritten oder auch anhand der ML Pipeline orientieren. In der Praxis hat sich gezeigt, dass in dieser Phase Teilaspekte der Systemspezifikation weiter verfeinert werden.

5. Phase: Übergabe

Nach der erfolgreichen Inbetriebnahme des ML-befähigten Produktionsprozesses erfolgt die Übergabe an den Anlagenbetreiber. Die Phase soll dem Anlagenbetreiber ermöglichen, den Produktionsprozess autonom betreiben zu können und regelmäßig anfallende Wartungs- und Anpassungsarbeiten weitgehend selbsttätig vorzunehmen. Deshalb sollte diese Phase durch entsprechende Qualifizierungsmaßnahmen mit Blick auf die neuen ML-Komponenten im Produktionsprozess begleitet werden.

Abschließend wird bei der Übergabe die Wirksamkeit der ML-basierten Anwendung mit Blick auf die initial definierten Projektziele aus Phase 1 – möglichst quantitativ – evaluiert.

6. Phase: Betrieb

Nach einer initialen Entwicklung und Anwendung von ML-basierter Prozessoptimierung stehen die Unternehmen vor neuen Herausforderungen, diese Lösungen dauerhaft im Betrieb zu etablieren. Grund ist die ständige Fortentwicklung der Fertigungsprozesse, etwa durch neue Produktvarianten wechselndes Eingangsmaterial, Verschleiß und Wartung, sowie strukturelle Umbauten an den Anlagen. Um die ML-Modelle in einer dynamisch veränderlichen Umgebung aktuell zu halten wird ein Prozess der kontinuierlichen Überwachung der Modellvalidität mit Modellupdates – auch durch Dritte – verfolgt und durch entsprechende Wartungswerkzeuge unterstützt.

Ausblick

Das skizzierte Vorgehensmodell wurde im Projekt ML4P am Beispiel von drei realen Produktionsprozessen – vom Umformprozess bis zur Herstellung von Membranfiltern – entwickelt und validiert. Ausführlicher dargestellt wird es in einem frei erhältlichen Whitepaper [2]. Am Fraunhofer IOSB werden derzeit die ersten Industrieprojekte auf Basis des Vorgehensmodells umgesetzt. Für die Kunden bietet dies eine Reihe von Vorteilen: Planbarkeit und Transparenz des Projektfortschritt und auf die zu erwartenden Kosten, die Möglichkeit der Skalierung auf große heterogene Teams und eine hohe Effizienz

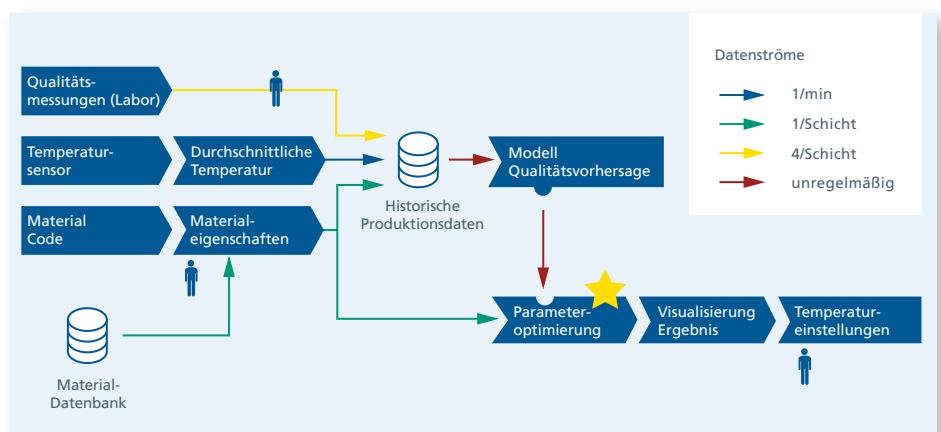
in der Entwicklung durch den Einsatz der speziell auf das Vorgehensmodell zugeschnittener Werkzeuge. **jbi**

Dr.-Ing. Julius Pfrommer, Leiter der Forschungsgruppe "Cyberphysische verteilte Systeme" in der Abteilung Informationsmanagement und Leittechnik des Fraunhofer IOSB.

Christian Frey, Leiter der Abteilung Mess-, Regelungs- und Diagnosesysteme am Fraunhofer IOSB.

[1] Was ist KI-Engineering? Webseite im Auftrag des Karlsruher Competence Center KI-Engineering, www.ki-engineering.eu/de/was-ist-ki-engineering

[2] Whitepaper: ML4P – Vorgehensmodell Machine Learning for Production. Fraunhofer, 2020. Download unter www.iosb.fraunhofer.de/ml4p



Beispiel eines Pipeline-Diagramm zur Parameteroptimierung der Ofentemperatur bei sich ändernden Eingangsmaterialien.