

Maschinelles

Lernen:

Anwendungen

für die Industrie

it's owl

Mehr Infos finden Sie auf:
www.its-owl.de

Folgen Sie uns:



INHALTSVERZEICHNIS

Vorwort: Maschinelle Intelligenz für den Mittelstand	3
Maschinelles Lernen (ML) und Künstliche Intelligenz (KI).....	4
ML in der industriellen Wertschöpfung	8
KI in der Produktionsplanung und -steuerung.....	10
KI-gestützte Absatzprognose	12
KI in der Supply Chain	15
Die Vision eines intelligenten Lagers	17
Effizienzsteigerung von Produktionsprozessen	20
KI-gestützte Prozessüberwachung	22
Condition Monitoring	23
KI auf dem Prüfstand	25
Ausblick: Die ML-Toolbox ML4ProFlow	27
Stimmen der Projektpartner	33
it's OWL e.V.....	34
Impressum.....	35

MASCHINELLE INTELLIGENZ FÜR DEN MITTELSTAND

WIR ZEIGEN WIE ES GEHT!

Künstliche Intelligenz, Maschinelles Lernen, Neuronale Netze, Deep Learning: Diese Forschungsansätze sind bei der Innovationsentwicklung für Intelligente Technische Systeme nicht mehr wegzudenken. Aber was verbirgt sich dahinter und welche Anwendungsmöglichkeiten gibt es in der industriellen Praxis?

Im Spitzencluster it'sOWL erschließen Unternehmen und Forschungseinrichtungen die Potenziale der maschinellen Intelligenz und entwickeln Lösungen für die Praxis. Dazu wurden bisher zahlreiche Innovations- und Transferprojekte auf den Weg gebracht, in denen Ansätze des maschinellen Lernens in den Bereichen Fertigung, Logistik, Produktentwicklung, Vertrieb und Services in die Anwendung gebracht wurden. Dabei geht es beispielsweise um vorausschauende Wartung und Qualitätsüberwachung, Absatzprognosen, unternehmensübergreifende Lieferketten und datenbasierte Geschäftsmodelle. Beteiligt waren beispielsweise große Unternehmen wie Claas, GEA, Diebold Nixdorf und Miele, aber auch KMU wie Schulte Kartonagen und Willich. Wichtige Grundlagen und Anwendungsbeispiele lieferte das Projekt „Maschinelles Lernen für die Produktion und deren Produkte“ unter der Koordination der Universität Bielefeld. Basistechnologien und Lösungsmuster werden in einem Baukasten für Unternehmen zur Verfügung gestellt.

Ergebnisse, Erfahrungen und Empfehlungen aus den Projekten haben wir in dieser Broschüre aufbereitet. Expertinnen und Experten aus den beteiligten Unternehmen und Forschungseinrichtungen berichten, wie sie Technologien der maschinellen Intelligenz für unterschiedliche Anwendungsfelder nutzbar gemacht haben und welche Wirkungen sie damit erzielt haben.

Lassen Sie sich inspirieren, um die Potenziale von maschineller Intelligenz für Ihr Unternehmen zu erschließen. Auf der it's OWL Innovationsplattform finden sie weitere Anwendungsbeispiele.

Nutzen Sie die vielen Angebote des Spitzenclusters, um die Ansätze auf Ihren Betrieb zu übertragen. Mit den it's OWL-Transfergutscheinen können Sie die Kompetenzen unserer Forschungseinrichtungen nutzen. Und das Mittelstand-Digital Zentrum Ruhr OWL hält viele weitere kostenlose Angebote für Sie bereit – beispielsweise Potenzialanalysen, Umsetzungsworkshops und KI-Transferprojekte.



Prof. Dr.-Ing. Roman Dumitrescu
 Geschäftsführer
 it's OWL Clustermanagement



Günter Korder
 Geschäftsführer
 it's OWL Clustermanagement



Dr.-Ing. Arno Kühn
 Leiter Strategie, FuE
 it's OWL Clustermanagement

Prof. Dr. Roman Dumitrescu | Günter Korder | Dr. Arno Kühn

MASCHINELLES LERNEN (ML) UND KÜNSTLICHE INTELLIGENZ (KI)

SCHLÜSSELTECHNOLOGIEN FÜR DIE INDUSTRIE DER ZUKUNFT

Künstliche Intelligenz (KI) hat in den letzten Jahren rasante Fortschritte gemacht. Mit Methoden wie maschinellem Lernen und Deep-Learning können moderne KI-Systeme Aufgaben wie Spracherkennung, Bilderkennung und Prognosemodellierung mit überraschender Genauigkeit ausführen. Diese Fortschritte haben dazu geführt, dass KI in immer mehr Bereiche des täglichen Lebens Einzug hält. Das jüngste Beispiel ist sicherlich der KI-Chatbot ChatGPT, der Ende vergangenen Jahres Schlagzeilen machte, da er Texte und auch Programm-Codes mit einer sehr hohen Qualität erzeugen und geschriebene, natürliche Sprache auf einem bislang unerreichten Niveau „verstehen“ kann.

Das Technologie-Netzwerk it's OWL fokussiert die Entwicklung, Integration und Optimierung intelligenter Tech-

nischer Systeme in industriellen Anwendungen. Der Begriff der Intelligenz bezieht sich dabei auf das Bestreben, die Systeme eigenständig bzw. autark agieren zu lassen, ohne, dass ein menschlicher Eingriff notwendig ist. In unseren ersten Projekten lag der Fokus stark auf dem Konzept der Selbstoptimierung. Seitdem hat sich sowohl in der Forschung als auch in der industriellen Anwendung der Begriff der künstlichen Intelligenz durchgesetzt. Aber was verstehen wir eigentlich unter dem Begriff „Künstliche Intelligenz“?

Als Künstliche Intelligenz wird ein System bezeichnet, das Aufgaben ausführen kann, ohne über spezifische Programmanweisungen zu verfügen (wie eine klassische Software). Stattdessen wird eine KI mit Hilfe von Eingangs-

bedaten und ggf. menschlichem Feedback so trainiert, dass ein Modell der durchzuführenden Aufgabe erzeugt wird. In dieses Modell können anschließend neue Daten als Input gegeben werden und die Künstliche Intelligenz löst die Aufgabe entsprechend. Diese Art des Lernens entspricht in Teilen den menschlichen Lernprozessen, daher spricht man hier von „künstlicher“ Intelligenz.

Weitere Begriffe, die in diesem Kontext häufig verwendet werden, sind maschinelles Lernen, Neuronale Netze oder Deep Learning. Der Zusammenhang dieser Begriffe wird in Abbildung 1 dargestellt.

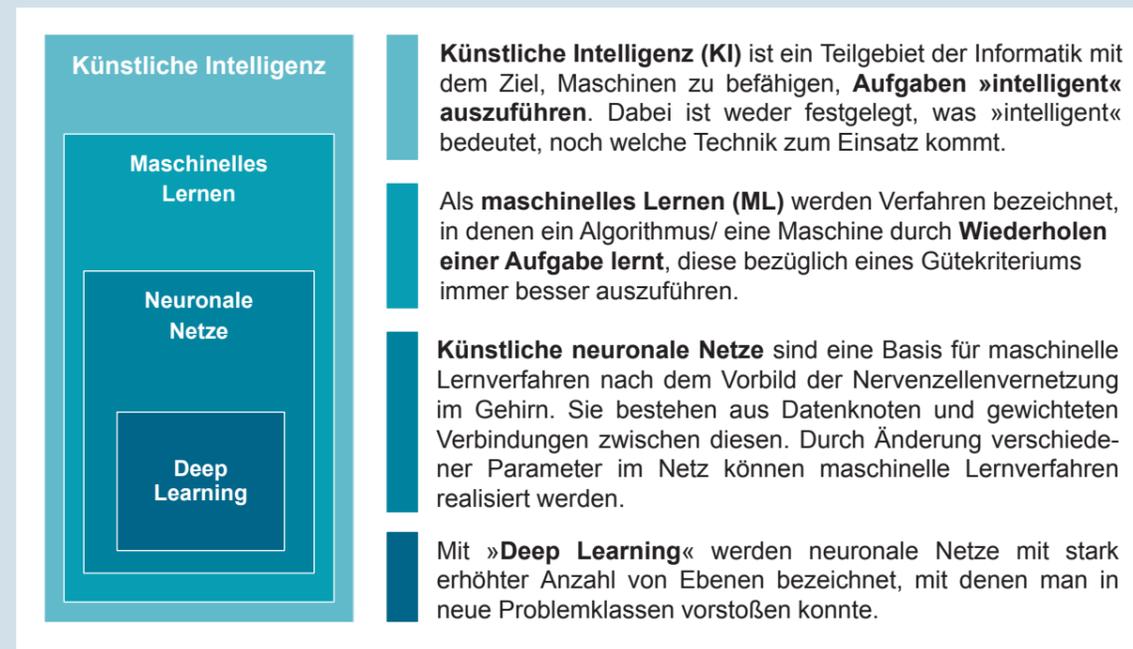
Im Zuge von Industrie 4.0 wurde die Vernetzung von Maschinen und Anlagen vorangetrieben. Hierdurch ergibt sich nicht nur die Möglichkeit der besseren Steuerung von Produktionsprozessen, sondern auch zur Auswertung der erzeugten Daten. Durch den Einsatz von Künstlicher Intelligenz ergeben sich so zahlreiche neue Potentiale.

Das Projektportfolio von it's OWL umfasst mittlerweile zahlreiche KI- und ML-Projekte. In einigen Projekten steht die Integration von ML- und KI-Ansätzen in die Produktion im Vordergrund. So auch beispielsweise im Projekt „ML4Pro“, in dem ein ML-Baukasten für Unternehmen entwickelt wurde, der es erleichtern soll, neue Lösungen in bestehende

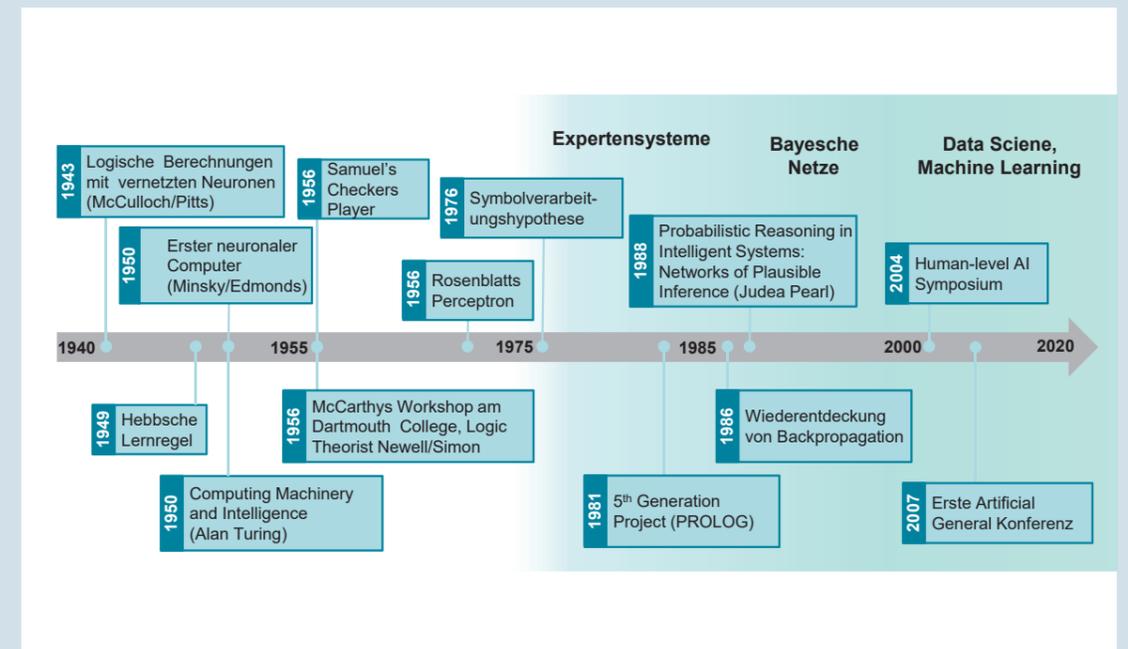
Prozesse zu integrieren. Ein Anwendungsbeispiel und ein Ausblick werden im Verlauf dieser Broschüre vorgestellt. Auch im Bereich der Logistik spielt KI eine wichtige Rolle bei der Optimierung von Prozessen und Abläufen oder auch zur Steigerung der Transparenz. Stellvertretend stehen die Projekte „IMAGINE“ mit dem Fokus auf die Optimierung von Intralogistikprozessen und das Projekt „MOVE“, in welchem KI zur Optimierung von unternehmensübergreifenden Lieferketten genutzt wird.

Ziel von „IMAGINE“ ist die Optimierung der Kernbereiche Auftragsabwicklung, Transport und Lagerhaltung innerhalb der Intralogistik. Gemeinsam mit den Partnerunternehmen Miele, GEA und Wilo werden in Pilotprojekten praxisrelevante und anwendungsnahe Lösungen entwickelt und erprobt. So sollen KI-Ansätze Miele zukünftig dabei unterstützen, die hochkomplexe Intralogistik im Unternehmen zu optimieren und eine automatisierte, effiziente Materialflussplanung zu ermöglichen. Im Projekt wird der Bogen von der Analyse der Ausgangssituation bis hin zur Schulung von Mitarbeitenden im Umgang mit Methoden Künstlicher Intelligenz gespannt. So erarbeiten die Expertinnen und Experten des Fraunhofer IEM beispielsweise einen Prozesskatalog zur Einführung von KI-Applikationen in bestehende Prozesse der Intralogistik. Weiterhin ermöglicht ein speziell entwickeltes KI-Technologieradar während der gesamten

Zusammenhang verschiedener Begriffe rund um KI (Abbildung 1)



Weitreichende Entwicklung: Rückblick bis in die 1940er-Jahre



Projektlaufzeit die kontinuierliche Leistungsüberwachung der eingesetzten KI-Technologien. Mehr zu diesem Projekt erfahren Sie in dieser Broschüre.

Im Projekt ‚MOVE‘ wird ein Aufgabenmodell für den Einsatz von KI im Supply Chain Management entwickelt, welches Vorgehensmodelle und wiederkehrende Lösungsmuster für Unternehmen bereitstellt. Diese basieren auf einer domänenübergreifenden Spezifikationstechnik, durch welche sowohl die Wirkzusammenhänge in Wertschöpfungsnetzen als auch die zugrundeliegenden IT-Systeme und Datenquellen abgebildet werden können. Hierzu kommen im Projekt verschiedene KI-Verfahren zur automatisierten Analyse und Optimierung von Wertschöpfungsnetzen zum Einsatz, die sukzessive weiterentwickelt werden. Der Fokus liegt dabei unter anderem auf der Integration von Expertenwissen.

Wie KI-Ansätze auch moderne Ernteprozesse verbessern können, wird im Projekt ‚InSenEPro‘ erforscht. Gemeinsam erproben CLAAS und die Universität Bielefeld, wie eine moderne Erntemaschine durch den Einsatz eines verteilten Sensornetzwerks in Kombination mit verschiedenen KI- und ML-Methoden weiter optimiert werden und so der Ernteertrag gesteigert.

Diese und weitere Lösungen verdeutlichen anschaulich die Chancen und Vorteile künstlicher Intelligenz für Unternehmen. In vielen weiteren Projekten erschließen wir darüber hinaus das Einsatzpotential Künstlicher Intelligenz für weitere Anwendungsbereiche, d.h. die Nutzung von KI-

bzw. ML-Ansätzen auch für Unternehmensbereiche fernab der Produktion wie z.B. in der Produktentwicklung. In der vorliegenden Broschüre stellen wir weitere spannende aktuelle Projekte und Industrie Use Cases vor, die die verschiedenen Einsatzmöglichkeiten von ML- und KI-Ansätzen anschaulich darstellen.

Wir sehen Künstliche Intelligenz als Schlüssel zur Lösung komplexer Probleme bzw. Aufgaben, die auf Daten basieren bzw. sich auf Daten reduzieren lassen. Vor diesem Hintergrund verwenden wir KI als Sammelbegriff, unter dem sich sowohl ML-Verfahren als auch Big-Data-Ansätze verorten lassen. Übergeordnetes Ziel ist nicht die Integration von Intelligenz als Selbstzweck, sondern die Lösung von realen Kundenproblemen.

Autor Forschung

M.Sc. Tommy Falkowski studierte Maschinenbau mit der Fachrichtung Produktentstehung an der Universität Paderborn. Seit 2015 ist er wissenschaftlicher Mitarbeiter am Fraunhofer-Institut für Entwurfstechnik Mechatronik IEM. Im Forschungsbereich Produktentstehung des IEM verantwortet er als Strategic Manager die Initiierung von strategischen Initiativen. Gleichzeitig ist er als Referent für Strategie, Forschung und Entwicklung beim Technologienetzwerk Intelligente Technische Systeme OstWestfalen-Lippe (it's OWL) tätig.



„Ohne die richtigen Experten ist es schwierig, maßgeschneiderte KI-Lösungen in die eigene Fertigung oder andere Bereiche eines Unternehmens zu integrieren. Gerade kleinere Unternehmen verfügen nicht über Teams von Data Scientists, die sich um diese Entwicklung kümmern können. Durch Kooperationen ist es aber auch für KMU problemlos möglich, die Potentiale von KI für sich zu erschließen. In unserem Technologienetzwerk it's OWL spielt der Technologietransfer zu KMU eine wichtige Rolle. In immer mehr von unseren Transferprojekten geht es um den Einsatz von KI-Lösungen in Industrieunternehmen.

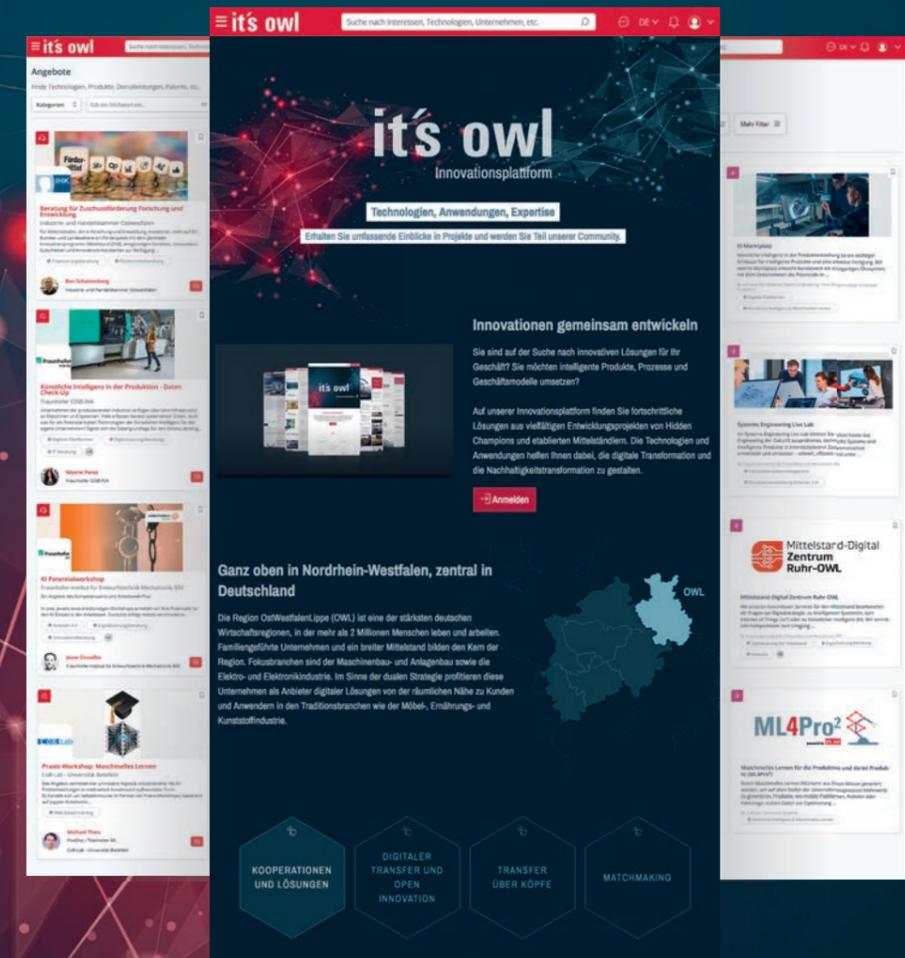
Durch die enge Zusammenarbeit von Experten aus den Unternehmen mit KI-Experten aus der Forschung können so passgenaue Lösungen entwickelt und Know-how aufgebaut werden.“

PROF. DR. ROMAN DUMITRESCU, it's OWL Geschäftsführer Strategie, FuE



Technologien. Anwendungen. Experten. Vernetzung.

Nutzen Sie unsere Innovationsplattform



ML IN DER INDUSTRIELLEN WERTSCHÖPFUNG

EINSTIEG UND UMSETZUNG

Die Entwicklungen im Bereich der intelligenten technischen Systeme führen derzeit zu einem Umbruch in der gesamten Wertschöpfungskette der industriellen Produktion. Vollvernetzte Produktionsanlagen reagieren adaptiv auf Veränderungen, Prozesse werden ressourcenoptimiert und die Bedienung und Wartung der Anlagen erfolgen intuitiv und zielgerichtet. Aufbauend ergeben sich datenbasierte Geschäftsmodelle, welche die integrierten technischen Möglichkeiten zu einem Mehrwert für die beteiligten Unternehmen führen. Diese Ansätze, wie beispielsweise vorausschauende Wartung oder Prozessoptimierung, basieren größtenteils auf Verfahren des maschinellen Lernens (ML).

Damit Ansätze des maschinellen Lernens umgesetzt werden können, müssen zunächst einige Voraussetzungen geschaffen werden. Als ein erster Schritt müssen die für die Problemstellung relevanten Daten vorliegen. Bei der Analyse eines Fertigungsprozesses sind diese beispielsweise einstellbare Parameter in der Prozessführung und relevante Zielgrößen für die Qualität der Produkte. Gegebenenfalls müssen diese Größen zunächst mittels einzubringender Sensorik beobachtbar gemacht werden. Alle Daten müssen schlussendlich in einer definierten Struktur abgelegt und zueinander synchronisiert werden, so dass diese, auch über mehrere Fertigungsschritte hinweg, vorliegen oder beispielsweise die Fertigung digital mit der Qualitätskontrolle verknüpft wird. Eine weitere Herausforderung besteht, vor allem in der industriellen Produktion, in der Unausgeglichenheit der Daten. Das heißt, die vorliegende Datenbasis besteht zu einem Großteil aus Daten für gute Produktionsergebnisse und enthält nur eine sehr kleine

Anzahl von Fehlerfällen. Dieses spricht zwar für den bestehenden Prozess, erfordert für die Anwendung maschineller Lernverfahren jedoch geeignete Kompensationsmaßnahmen wie entsprechend parametrierbare Zielvorgaben für das Training und muss auch bei der Interpretation bzw. Nutzung der Ergebnisse beachtet werden.

Als Einstieg in die Nutzung maschineller Lernverfahren im Unternehmen steht zunächst die Auswahl geeigneter Problemstellungen aus der eigenen Produktion. Dabei sollte die Anwendung von ML kein reiner Selbstzweck sein, sondern sich auf komplexe Prozesse fokussieren, die über eine Vielzahl von Parametern und somit Abhängigkeiten verfügen und die Einstellung „nach Gefühl“ entweder sehr zeitaufwendig oder nicht sicher reproduzierbar ist. Also Prozesse, die analytisch nicht oder nur schwer zu beherrschen sind. Bei der Auswahl der Problemstellung sollte zudem das Verhältnis zwischen Aufwand (Sensorik, Datenerfassung) und dem zu erwartenden Nutzen (Produktqualität, Ausschuss, Gesamtanlageneffektivität) beachtet werden. Als Startpunkt dient somit idealerweise eine Anwendung mit bereits bestehender Datenlage oder leicht zugänglichen Daten, die über eine gewisse Skalierbarkeit im Unternehmen verfügt.

Dabei kann es hilfreich sein, sich in Hinblick auf ein angestrebtes Fernziel zunächst auf gut verständliche Teilprobleme zu fokussieren. Auf diese Weise wird im Unternehmen Kompetenz hinsichtlich der Möglichkeiten der Anwendung und der Interpretierbarkeit der Ergebnisse aufgebaut. Beispielsweise könnten die Ergebnisse der maschinellen Lernverfahren zusammen mit den Pro-

zessexpert:innen des Unternehmens ausgewertet und so ein gemeinsames Verständnis geschaffen werden. Deren Prozess- bzw. Domänenwissen stellt oftmals auch den Startpunkt in einem Umsetzungsprojekt dar, da diese die für den Prozess besonders relevanten Parameter nennen und die Qualität des Prozesses bewerten können. Dieses Wissen kann sowohl in formalisierter Form in die ML-Verfahren einfließen (Feature Engineering), als auch, bei erkläraren ML-Verfahren, der Plausibilitätskontrolle dienen. Auf diese Weise kann zudem das Verständnis und somit auch die Akzeptanz der ML-basierten Vorhersagen bei den menschlichen Expert:innen gesteigert werden.

Die Umsetzung der ML-Verfahren sollte durch Mitarbeitende mit der entsprechenden Expertise und im stetigen Dialog mit Mitarbeitenden der Prozessführung erfolgen. Falls im Unternehmen noch keine Expertise im Bereich ML

aufgebaut wurde, können die ersten Schritte auch über Kooperationen mit Forschungseinrichtungen oder Dienstleistern erfolgen. Da Lösungen mittels ML-Verfahren jedoch nicht als einmalige abgeschlossene Aufwendung betrachtet werden können, sondern als kontinuierlicher Prozess, sollten Unternehmen hier mittelfristig eigene Expertise aufbauen. Beispielsweise über die Gewinnung von Absolvent:innen der entsprechenden Studiengänge der Hochschulen in der Region.

Somit kann die zu entwickelnde ML-Lösung über den gesamten Lebenszyklus, wie dem kontinuierlichen Nachtraining auf einer wachsenden Datenbasis oder zur Erweiterung der Aufgabenstellung für das ML-Verfahren, der Anpassung an wechselnde Kundenwünsche, oder bei Drift der Daten begleitet werden, so dass sich diese auch nachhaltig im Produktiveinsatz nutzen lässt.

Autor Forschung

Dr. Michael Thies ist Teamleiter für das Themenfeld Maschinelles Lernen in der Arbeitsgruppe Kognitronik und Sensorik an der Universität Bielefeld. Der Informatiker beschäftigt sich schwerpunktmäßig mit datensparsamen und effizienten ML-Methoden, die ideal auf die praktischen Randbedingungen und organisatorischen Anforderungen aus der Industrie abgestimmt sind.



Autor Forschung

Dr. Marc Hesse ist Teamleiter für das Themenfeld Kognitronik in der Arbeitsgruppe Kognitronik und Sensorik an der Universität Bielefeld. Er koordinierte das Projekt „ML4Pro²“, in dessen Rahmen die Toolbox ML4Pro²Flow entstanden ist. Sein Forschungsschwerpunkt liegt u.a. auf dem modellbasierten Entwurf eingebetteter Systeme für ML-Anwendungen.



KI IN DER PRODUKTIONSPLANUNG UND -STEUERUNG

TROTZ KONKURRIERENDER ZIELFUNKTIONEN ZUR NUTZENFUNKTION

Die Josef Schulte GmbH ist ein Kartonagenhersteller aus Delbrück mit Expertise in der Herstellung von Kartonagen und Verpackungslösungen. Das Familienunternehmen bietet ein Portfolio aus mehr als 28.000 verschiedenen Kartonagen an. Eine große Herausforderung liegt dabei in der Produktionsplanung und -steuerung, insbesondere bei der Erstellung eines Produktionsfeinplanes. Hier treffen verschiedene Zielfunktionen aufeinander, die miteinander konkurrieren. Die Einhaltung einer hohen Termintreue, eine Minimierung der Rüstzeiten an den Maschinen, oder die Reduzierung der Logistikkosten sind Aspekte, die gleichsam Beachtung finden müssen. Zur Vereinfachung der Produktionsplanung und zur Unterstützung der in Verantwortung stehenden Mitarbeitenden, soll an dieser Stelle mittels KI interveniert werden. Doch ist

es weder trivial, die verschiedenen Einflussfaktoren beispielsweise linear gegeneinander abzuwägen, noch lässt sich die Güte eines Produktionsplanes anderweitig direkt zahlenmäßig ausdrücken. Menschen können einzelne Parameter oftmals clustern und somit paarweise vergleichen, um daraus abgeleitet Präferenzen bilden. Ziel des Use-Cases ist es daher, Methoden des Präferenzlernens anzuwenden, um aus relativen Vergleichen zwischen Produktionsplänen eine Nutzenfunktion zu lernen, welche anschließend z.B. mit herkömmlichen Optimierern verwendet werden kann, um Produktionspläne vorzuschlagen.

Ein erster Ansatz für das Präferenzlernen geht davon aus, dass es einen bestehenden Datensatz paarweiser Vergleiche gibt. Dieser kann entweder durch direktes Ab-

fragen von Vergleichen durch einen menschlichen Planer erfolgen, indem dieser vergangene Pläne heranzieht, oder durch Erzeugen von Permutationen aus historischen Daten. Unter der Annahme, dass die vergangenen Pläne ausreichende Güte aufweisen, lässt sich ein Vergleich aus einem Plan und einer Alternativversion des Plans, bei dem Aufträge getauscht werden, bilden. Basierend auf den paarweisen Vergleichen wird dann ein Rankingmodell trainiert. Anspruch ist dabei, dass die Güte, obwohl paarweise gelernt, später punktweise berechnet werden kann, da die meisten Optimierungsalgorithmen davon ausgehen, dass eine Kandidatenlösung einzeln bewertet wird. Der letzte Schritt des Ansatzes ist, die erlernte Nutzenfunktion mit einem Optimierungsalgorithmus zu verbinden. Hier sind, je nach Problemstellung, beispielsweise exakte Lösungen über Solver, oder Metaheuristiken wie evolutionäre Methoden, denkbar.

Herausforderungen ergeben sich in der Umsetzung in zweierlei Hinsicht. Die Umsetzung erfordert eine hohe Datenqualität, die im konkreten Anwendungsfall nicht durchgehend gegeben war, sodass Daten teilweise händisch nachgepflegt werden mussten, was ein gewisses Fehlerpotenzial birgt. Durch die Einführung eines MES-Systems, welches Zustände wie Maschinenstatus automatisch aktualisiert, konnte dies verbessert werden. Eine weitere Herausforderung für jede algorithmische Anwendung im Bereich der Produktionsplanung ist die komplexe Struktur des Lösungsraumes für Scheduling-Probleme. Bei Fällen der Klassifikation oder Regression ist der Standardfall, dass ein Modell des maschinellen Lernens von einem Eingangsvektor auf eine Klasse oder einen numerischen Wert abbildet. Bei einem Scheduling-Problem besteht eine Lösung jedoch, je nach Definition, aus der Zuweisung von Aufträgen zu Maschinen, sowie

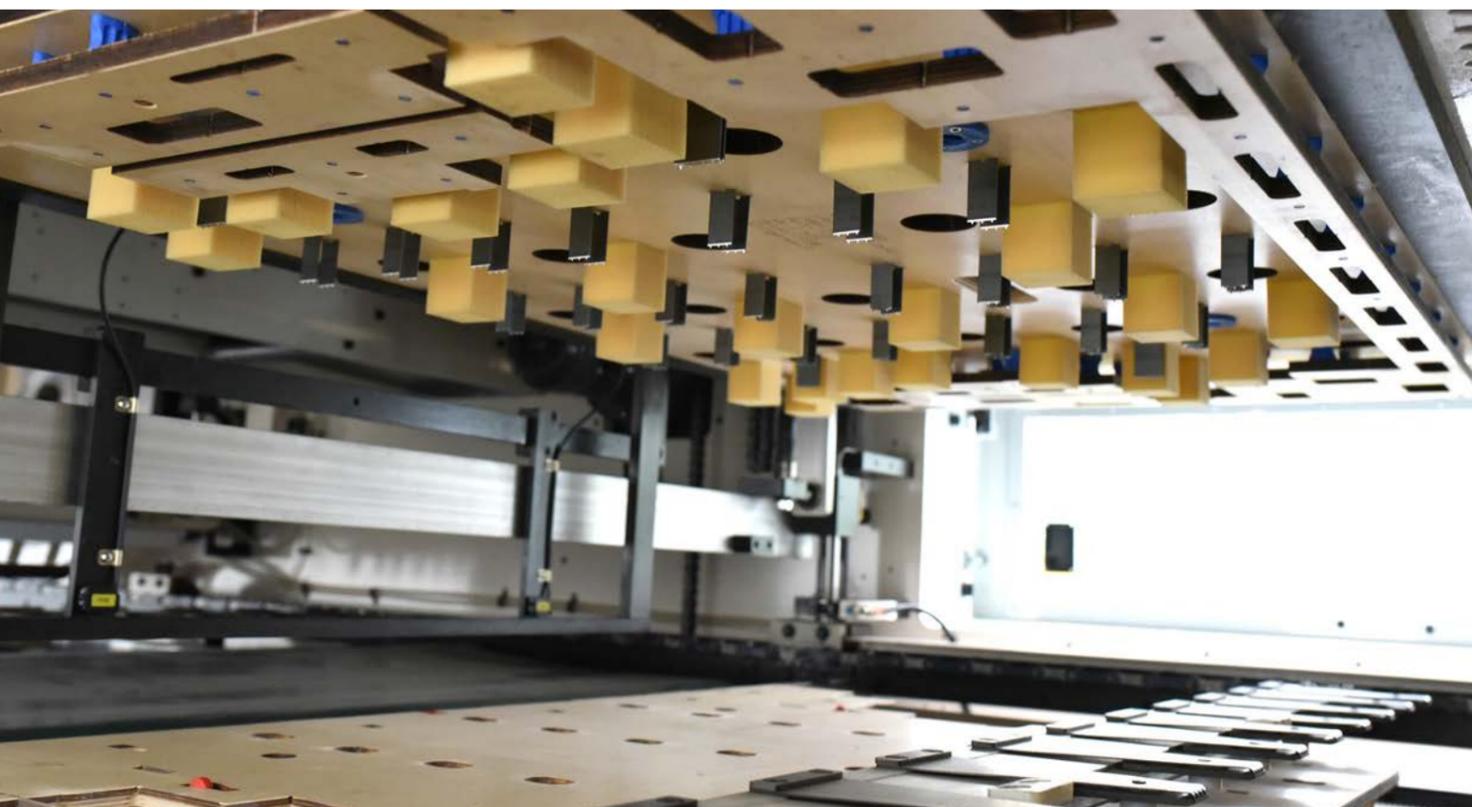
der Zuweisung von Zeitslots auf den Maschinen für einzelne Aufträge. Dieser Komplexität kann zum Beispiel dadurch entgegengewirkt werden, dass im Rahmen der anfänglichen formalen Problemdefinition nur wirklich relevante Aspekte abgebildet werden.

Die technische Umsetzung der Lösung erfolgt in Form eines webbasierten Prototyps. Ein Vue-Frontend soll Interaktion mit aktuellen Auftragslisten sowie aktuellen und algorithmisch erstellten Produktionsplänen erlauben. Ein Django-Backend stellt den Konnektor zu der internen ERP-Datenbank her und verwaltet Datenvorverarbeitung sowie Modelle und Planungsalgorithmen. Die Modelle werden dabei im Prototyp zur Abfrage verwendet, und werden wie beschrieben auf Vergleichsdaten vortrainiert. Verwendete Programmiersprache ist dabei hauptsächlich Python. Um bezüglich der im Deployment und Development verwendeten Hardware und Betriebssysteme möglichst flexibel zu bleiben und iterative Deployments mit inkrementellen Verbesserungen schnell umsetzen zu können, werden Container verwendet.

Während der Bearbeitung des Use Cases gab es einige ‚Lessons Learned‘. Einerseits zeigt sich immer wieder, wie essenziell eine gute Datengrundlage für die Anwendung von maschinellem Lernen ist. Andererseits zeigte sich die Wichtigkeit einer guten Problemdefinition.

Wann immer der Einsatz von ML angedacht ist, sollte in einem ersten Schritt an die vorliegende Datenqualität gedacht und anschließend Möglichkeiten eruiert werden, wie diese gegebenenfalls optimiert werden können. Grundsätzlich ist es, je nach Ausgangslage, denkbar, den in diesem Use-Case erarbeiteten Ansatz für andere Anwendungsdomänen nutzbar zu machen.

Mithilfe der Methoden des Präferenzlernens zu vereinfachten Produktionsplänen



Autorin Forschung

Helena Graf ist wissenschaftliche Mitarbeiterin in der Gruppe Advanced Systems Engineering an der Universität Paderborn. Dort erwarb sie ihren Bachelor und Master in Informatik, mit einer Spezialisierung in Intelligence and Data. Ihre Forschungsinteressen liegen im Bereich des maschinellen Lernens, speziell des Präferenzlernens. Im industriellen Kontext beschäftigt sie sich mit der Anwendung von Präferenzlernen für Scheduling, im Rahmen der Produktionsplanung und -steuerung.



Autor Industrie

Pascal Pöhler ist Prokurist der Josef Schulte GmbH. Nach seinem Master des Wirtschaftsingenieurwesens an der Universität Paderborn stieg er als Assistent der Geschäftsführung bei dem mittelständischen Verpackungsspezialisten ein. Mittlerweile verantwortet er die Forschungsprojekte der Josef Schulte GmbH sowie die Automatisierung und Vernetzung der Systemlandschaft.



KI-GESTÜTZTE ABSATZPROGNOSE

DANK FORECAST ZU ABTEILUNGSÜBERGREIFENDEN BENEFITS

Die Alfred Willich Produktions GmbH ist Hersteller von Überzugsmassen (bspw. des Pfefferrands für Salami), Ölmarinaden, Feinkost und weiteren flüssigen (non-) Food Produkten. Mit rund 300 Produkten im Sortiment, Kunden in 26 Ländern und einer Exportquote von 40% besitzt das KMU aus Versmold (Kreis GT) eine vielschichtige B2B-Absatzstruktur. Gleichzeitig ist Willich Vorreiter in Sachen Digitalisierung in der KMU-Lebensmittelbranche und nutzt IT-Systeme im großen Umfang, um datenbasierte Entscheidungen treffen zu können. Die Unternehmenskultur ist geprägt durch eine hohe Innovationsfreude und Technologieaufgeschlossenheit. So verwendet das Unternehmen Power BI bereits für die Auswertung von Produktions- und Qualitätsdaten.

In diesem Zuge ist der Entschluss gefallen, in Zusammenarbeit mit dem Fraunhofer IEM eine Vorhersage für den Absatz ihrer Produkte zu entwickeln. Dieser Forecast teilt sich dabei auf zwei Aspekte auf: zum einen die Algorithmen inkl. der Herangehensweise zur Vorhersage des Absatzes und zum anderen die sozio-technische Einbettung der Informationen in das Power BI Ökosystem bei Willich. Um den zweiten Aspekt zu ermöglichen, verfolgt das Fraunhofer IEM das Ziel der frühen Integration von Mitarbeitern in den Entwurfsprozess. Wie in Abbildung 1 dargestellt, wurden in Workshops gemeinsam mit den schlussendlichen Nutzern des Absatzforecasts iterativ zunächst Anforderungen und Erwartungen definiert. Dafür wurden insbesondere die anzuzeigenden Kennzahlen – die neben

dem eigentlichen Forecast erwünscht sind – systematisch in Form eines Kennzahlensystems erschlossen. Diese Informationen wurden gemeinsam in Workshops zu Skizzen der finalen Dashboards zusammengeführt und frühzeitig in Power BI auf Basis von Beispieldaten überführt, sodass durch die praktische Nutzung vorzeitig Feedback in die Entwicklung einfließen konnte.

Parallel dazu wurde die Entwicklung der Algorithmen zur Vorhersage des Absatzes durchgeführt. Dafür erfolgt zunächst eine Charakterisierung der Artikel hinsichtlich des Nachfrageverhaltens auf Basis historischer Absätze (vgl. Produktsteckbriefe auf der linken Seite in Abbildung 2). Diese Charakterisierung erfolgt dabei unter anderem nach den durchschnittlichen Abständen zwischen Absätzen und der Variation der Absatzmengen. Durch diese Analyse des Nachfrageverhaltens konnten die Produkte für die Entwicklung von Prognosemodellen priorisiert werden, da nicht alle Produkte gleich gut für eine Absatzprognose geeignet sind (bspw. sind hohe Zeiträume zwischen zwei Absätzen mit großen Unterschieden in der Absatzmenge weniger gut geeignet). Für die priorisierten Produkte können nun die Prognosen erstellt werden. Das Fraunhofer IEM verfolgt dabei den Ansatz des Multiple Aggregation Prediction Algorithm (MAPA, dt. mehrfacher aggregationsvorhersage

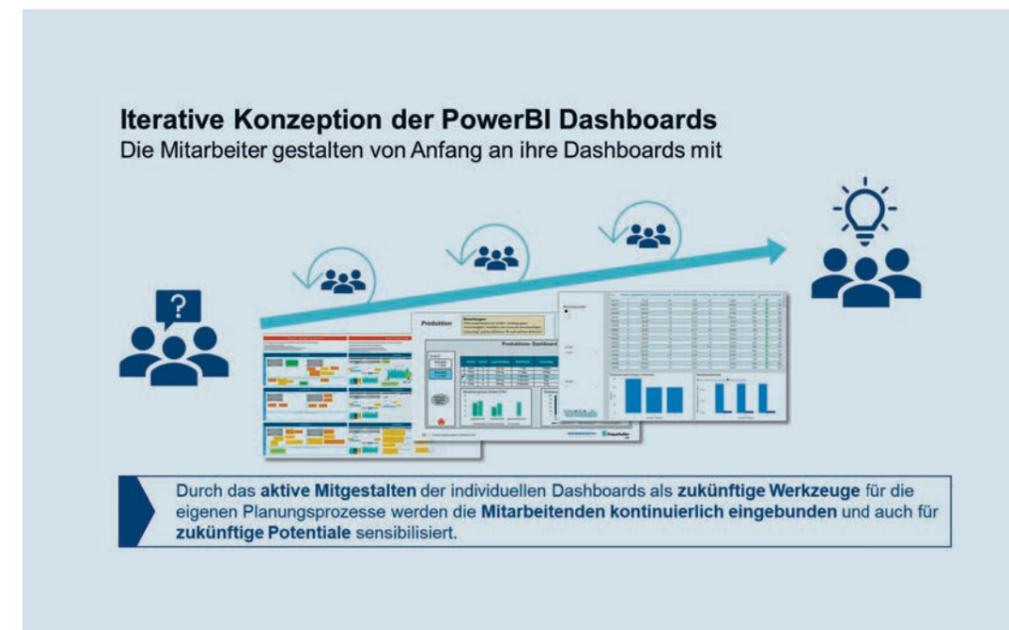
Algorithmus). Dies bedeutet, dass unterschiedliche Ansätze, Vorhersagemethoden und Algorithmen zu einer einzigen Vorhersage kombiniert werden. Der Vorteil besteht darin, dass sich die Ansätze in ihren Stärken ergänzen („alle sind sich einig“) und in ihren Schwächen abdämpfen („einer sagt einen Ausreißer vorher“). Unter den Ansätzen finden sich Algorithmen wie ARIMA, k-nearest neighbours oder simple Ansätze wie ein gleitender Durchschnitt. In den MAPA schaffen es nur die Algorithmen, die die beste Leistung – gemessen an verschiedenen Gütekriterien – erbringen. Exemplarische Prognoseergebnisse finden sich in Abbildung 2 auf der rechten Seite.

Die Kombination von Power BI und Forecast erfolgte in der Willich Umgebung. Der Algorithmus berechnet in definierten Zeitintervallen die Vorhersage für den gewählten Zeitraum. Die Ergebnisse werden in einer Tabelle in der Datenbank von Willich abgespeichert und von Power BI aufgerufen. So liegen nicht nur die aktuellen Vorhersagen vor, sondern es lässt sich auch die historische Übereinstimmung verifizieren. Die Endnutzer können die Forecasts ganz einfach in Power BI nach ihren Vorstellungen filtern und anzeigen lassen. Unterschiedliche Fachbereiche profitieren dadurch auf verschiedene Weise. Der Vertrieb kann sprunghafte Absätze frühzeitig erkennen und das

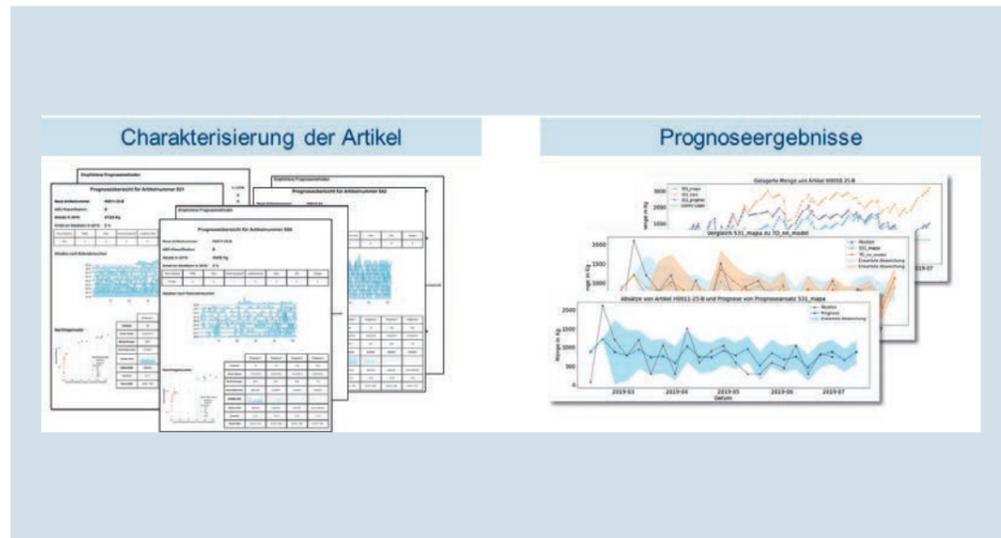
Produktionshalle der Alfred Willich GmbH



Mitarbeiterbindung bei der Entwicklung der Dashboards (Abbildung 1)



Produktsteckbriefe zur Charakterisierung der Artikel sowie der erzielten Prognoseergebnisse (Abbildung 2)



proaktive Gespräch mit den Kunden gehen, die Produktionssteuerung kann die Produktionsreihenfolge effizient abstimmen und der Einkauf profitiert vom Blick in die Zukunft, indem entsprechend des Forecasts Rohstoffe zugekauft werden können. Innerhalb des Projektes hat Willich zusammen mit dem Fraunhofer IEM ein Power BI-Dashboard bei sich in Betrieb genommen. Dieses zeigt neben existierenden operativen Kennzahlen auch noch im Projekt definierte und berechnete KPI. Krönung ist der entwickelte Forecast, der die zukünftigen Absätze der verschiedenen Produkte vorhersagt. Durch die frü-

he Integration der Mitarbeitenden in die Entwicklung der Lösung erfreut sich das Werkzeug an hoher Akzeptanz und wird täglich von unterschiedlichen Bereichen genutzt. Die Vorhersagen treffen den tatsächlichen Absatz hervorragend und ermöglichen dem Vertrieb, der Produktion und dem Einkauf eine bessere Koordination und Planung ihrer Tätigkeiten. Und dieses Projekt ist erst der Anfang: die Alfred Willich GmbH wird eigenständig die Forecasts auf weitere Produkte ausweiten und die Power BI Dashboards eigenständig nach ihren Vorstellungen erweitern.

Autor Forschung

Jonathan Brock ist wissenschaftlicher Mitarbeiter im Bereich Industrial Data Analytics am Fraunhofer IEM in Paderborn. Der Wirtschaftsingenieur zählt vor allem prozesszentrierte Überwachung und Steuerung von Geschäftsprozessen mithilfe von maschinellem Lernen und Process Mining zu seinen Forschungsschwerpunkten.



Autor Industrie

Volker Willich ist Geschäftsführer der Alfred Willich Produktios GmbH in Versmold. Der Diplom Chemieingenieur treibt seit fast drei Jahrzehnten gemeinsam mit seinen rund 25 Mitarbeitern die Innovation der Lebensmittelproduktion voran – sowohl in den Produkten als auch den Prozessen.



KI IN DER SUPPLY CHAIN

KOMPLEXE LIEFERTERMINPROGNOSEN OPTIMIEREN

Diebold Nixdorf (DN) ist einer der weltweit führenden Anbieter von Lösungen im Bereich „Connected Commerce“. Weltweit hat DN über 2 Millionen Geldautomaten und POS-Systeme installiert. Die Lösungen sind stets kundenspezifisch angepasste Varianten, die in vielen Fällen im Rahmen der Auslieferung eine präzise geplante Installation am Kundenstandort erfordern. Im Rahmen des it's OWL Innovationsprojekts „MOVE“ untersucht DN die Potenziale des ML im Kontext einer Lieferterminprognose am Beispiel ausgewählter Lösungen. Dem Vertrieb ist es ein Anliegen, Kunden im Gespräch eine stabile und zuverlässige Lieferterminprognose bieten zu können, die als wesentlicher Wettbewerbsvorteil gesehen wird. Aufgrund vieler unterschiedlicher Einflussfaktoren entlang des Wertschöpfungsnetzes ist die Lieferterminprognose jedoch komplex.

Um trotzdem eine stabile und zuverlässige Lieferterminprognose ermöglichen zu können, wurde der Lösungsbereitstellungsprozess zunächst in vier Teilprozessschritte zerlegt: Beschaffung, Fertigung, Versandvorbereitung und Versand. Für jeden der einzelnen Teilprozessschritte erfolgt eine separate Bereitstellungszeitprognose, die schlussendlich zur Lieferterminprognose zusammengeführt werden kann. Zur Prognose der benötigten Zeiträume werden zwei verschiedene Ansätze verfolgt, die jeweils die Vergangenheitsdaten der einzelnen Prozessschritte verarbeiten. Einerseits werden etablierte statistische und stochastische Methoden in einem Expertensystem gebündelt, um basierend auf den Vergangenheitsdaten eine Prognose zu ermöglichen. Andererseits baut ein AutoML-Ansatz ein statistisches Modell für die Prognosen der einzelnen Teilprozessschritte auf. Nach ihrer Fertigstellung werden die beiden Ansätze bzgl. ihrer Zuverlässigkeit in den einzelnen Teilprozessschritten evaluiert bzw. verglichen. Der jeweils bessere Ansatz trägt seinen Teil zur Lieferterminprognose bei. DN ver-

folgt dieses parallele Vorgehen, da aufgrund der Vielzahl und Diversität der möglichen Einflussfaktoren auf die Prognose die Zuverlässigkeit der Prognose des ML-Ansatzes anzuzweifeln ist.

Bei der Zerlegung des Bereitstellungsprozesses wurden mehrere Herausforderungen identifiziert. (1) Die von DN produzierten Lösungen sind von komplexer Natur und weisen unzählige unterschiedliche Bestandteile auf. Dies stellt eine enorme Herausforderung für die Beschaffungszeitprognose dar. Daher muss DN im Rahmen der Beschaffung entscheiden, welche Materialien bzw. Bestandteile für die Prognose der Beschaffungszeit herangezogen werden. (2) Eine weitere Herausforderung im Rahmen der Beschaffungszeitprognose sind die von DN angebotenen kundenspezifischen Lösungsvarianten, die durch konfigurierbare Stücklisten innerhalb des ERP-Systems abgebildet sind. Als Konsequenz unterscheiden sich Lösungen des gleichen Typs in den verbauten Materialien – teils nur in Nuancen. Dies erschwert die Identifikation relevanter Lösungen bzw. Materialien innerhalb der Vergangenheitsdaten. (3) Eine weitere beschaffungsspezifische Herausforderung besteht in der Einkaufspolitik. Materialien werden in der Regel nach Plan und unabhängig von Aufträgen beschafft. Deshalb gibt es innerhalb des ERP-Systems keine direkte Verknüpfung von Beschaffung und Fertigungsauftrag. (4) Auch bei der Produktionszeitprognose stellen die kundenspezifischen Lösungsvarianten eine Herausforderung dar und erschweren die Identifikation relevanter Vergangenheitsdaten. (5) Die Prognose der Versandzeiten ist ebenfalls mit einer großen Herausforderung verbunden. DN bietet Kunden die Möglichkeit, Lösungen auf dem Luft-, See- oder Landweg zu erhalten und setzt dafür auf viele verschiedene Logistikpartner. Da die Etablierung von Datenaustauschschnittstellen für einige Logistikpartner noch aussteht, sind die Daten nicht für alle Transportvarianten bzw. Zieldestinationen belastbar.

Delivery Forecasting

Please select a Product.

DN200

Product Name
DN200A Compact FL

Country Code
Germany

Transport Mode
Truck

Material
1750313000

Name
DN200A Compact FL

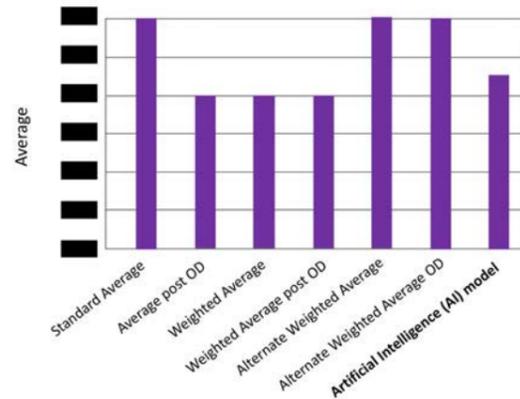
Model
DN Series 200A Compact

Line
DN Series

Family
Cash Dispensers

Segment
Banking Systems

Estimate



Darstellung der Prognoseergebnisse für die Lieferdauer im rollenspezifischen, detaillierten Frontend: Innerhalb eines Bar-Charts werden die Ergebnisse verschiedener Prognoseansätze aufbereitet, um schnell und einfach vergleichbar zu sein.

DN sammelt die innerhalb der einzelnen Teilprozessschritte anfallenden Daten innerhalb einer zentralen Datenbank, die die Daten für die beiden Prognoseansätze zur Verfügung stellt. Verfügbare versandspezifische Daten, sowie Daten aus dem ERP-System bzgl. Produktion und Versandvorbereitung werden bereits zentral gespeichert. Beschaffungsspezifische Daten werden noch nicht gesammelt, da die Identifikation der relevanten Materialien noch nicht abgeschlossen ist. Die beiden Prognoseansätze befinden sich derzeit in der Implementierung. Das Expertensystem ist weiter fortgeschritten und kann bereits Prognosen für die Teilprozessschritte Produktion, Versandvorbereitung sowie Versand basierend auf den Vergangenheitsdaten von etwa zweieinhalb Jahren generieren. Die Implementierung des ML-Ansatzes wurde erst vor kurzem begonnen und liefert noch keine belastbaren Prognosen, da die Modellbildung noch nicht abgeschlossen ist. Ein Konzept für die Datenvisualisierung wird aktuell im Rahmen der Frontend-Implementierung des Expertensystems vorangetrieben. Hier wird das Ziel

verfolgt, dass im weiteren Projektverlauf die Möglichkeit besteht, innerhalb des Backends das Expertensystem durch den ML-Ansatz zu ersetzen, ohne das Frontend anpassen zu müssen. So werden beispielsweise innerhalb der Datenvisualisierung sowohl die Ergebnisse des ML-Ansatzes als auch des Expertensystems angezeigt (siehe Bild). Das Frontend wird rollenspezifisch aufgesetzt: Der Vertrieb erhält den prognostizierten Liefertermin, wohingegen andere Anwender (aktuell v.a. die Entwickler), die Ergebnisse in einer deutlich detaillierter aufbereiteten Form einsehen können. Im Rahmen des Forschungsprojekts beschränkt sich DN auf die Lieferterminprognose für wenige exemplarisch ausgewählte Lösungen aus den Segmenten Banking und Retail. Darüber hinaus sind die Prognosen aktuell standortspezifisch für Paderborn, da aufgrund bestehender Systemgrenzen nur Vergangenheitsdaten aus diesem Werk gesammelt werden. Langfristig wird jedoch ein weltweiter und die komplette Lösungspalette überspannender Einsatz der Lieferterminprognose angestrebt.

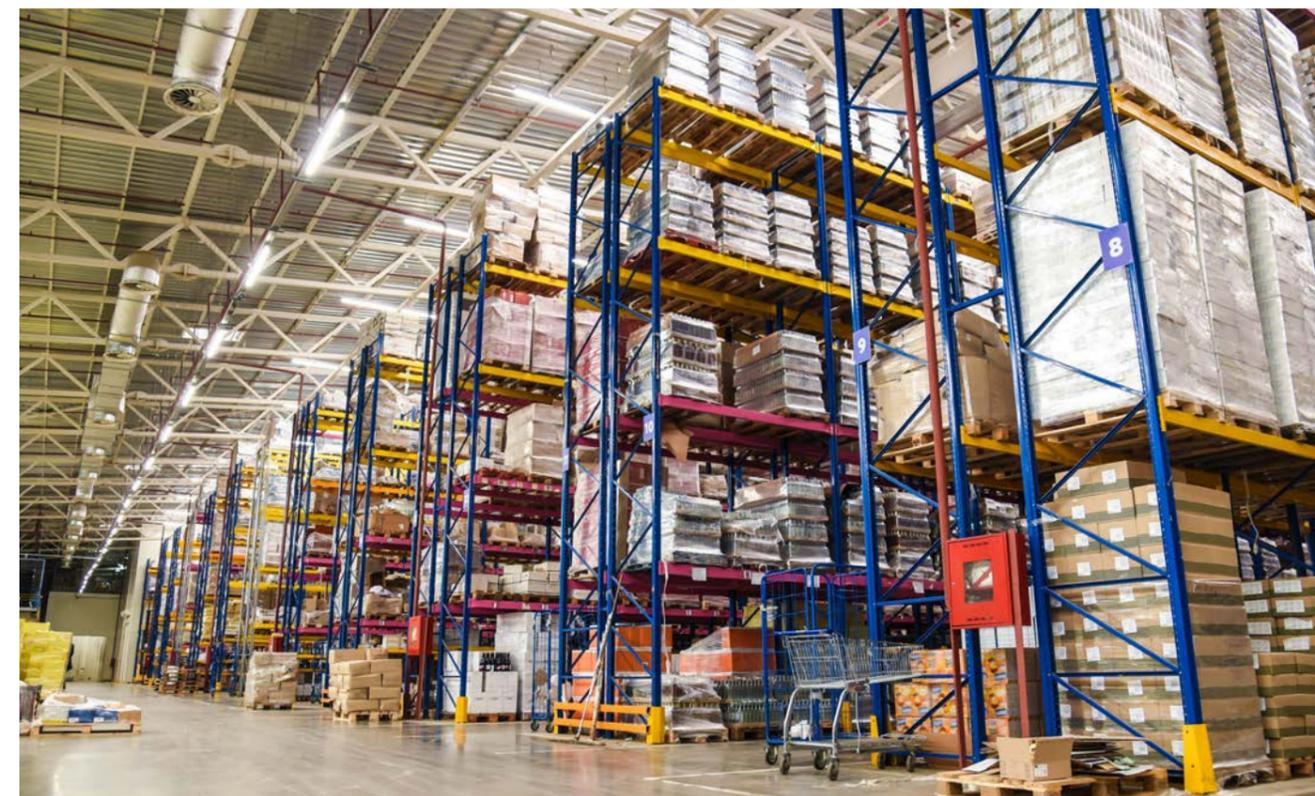
DIE VISION EINES INTELLIGENTEN LAGERS

WIE LAGERLOGISTIK MITTELS KI NOCH EFFIZIENTER WERDEN KANN

Im it's OWL-Projekt 'IMAGINE' (Instrumentarium zur Gestaltung einer KI-gestützten Intralogistik produzierender Unternehmen) erforscht Miele gemeinsam mit dem Fraunhofer IEM, wie es seine Logistik im Lager mit Künstlicher Intelligenz noch besser machen kann. Die zentrale Frage an die KI ist: Wie wissen wir schon bei Einlagerung eines Bauteils, wann und in welcher Kombination es spä-

ter in die Produktion geht? Wie identifizieren wir den besten Lagerort? Die Vision dazu ist das intelligente Lager mit einer dynamischen Platzzuweisung von Bauteilen. Neu angeliefertes Material wird erfasst und automatisch dem optimalen Lagerplatz zugeordnet. Die Mitarbeiterinnen und Mitarbeiter im Lager profitieren von kürzeren Wegen und können flexibler und effizienter in die Produktion liefern.

Mehrwert für Unternehmen und Umwelt: Mittels KI Fahrwege in der Lagerlogistik minimieren



Autor Forschung

Benedict Wohlers besitzt einen Master of Science in Informatik und ist seit 2014 wissenschaftlicher Mitarbeiter des Fraunhofer IEM. Er unterstützt Diebold Nixdorf im it's OWL Innovationsprojekt 'MOVE' bei der Umsetzung der Lieferterminprognose.



Autor Industrie

Timo Vondereck ist Senior Manager Manufacturing Technologies and Security Engineering. Wir unterstützen das it's OWL Innovationprojekt 'MOVE' als Team bei der Analyse und der technischen Implementierung bei DN.

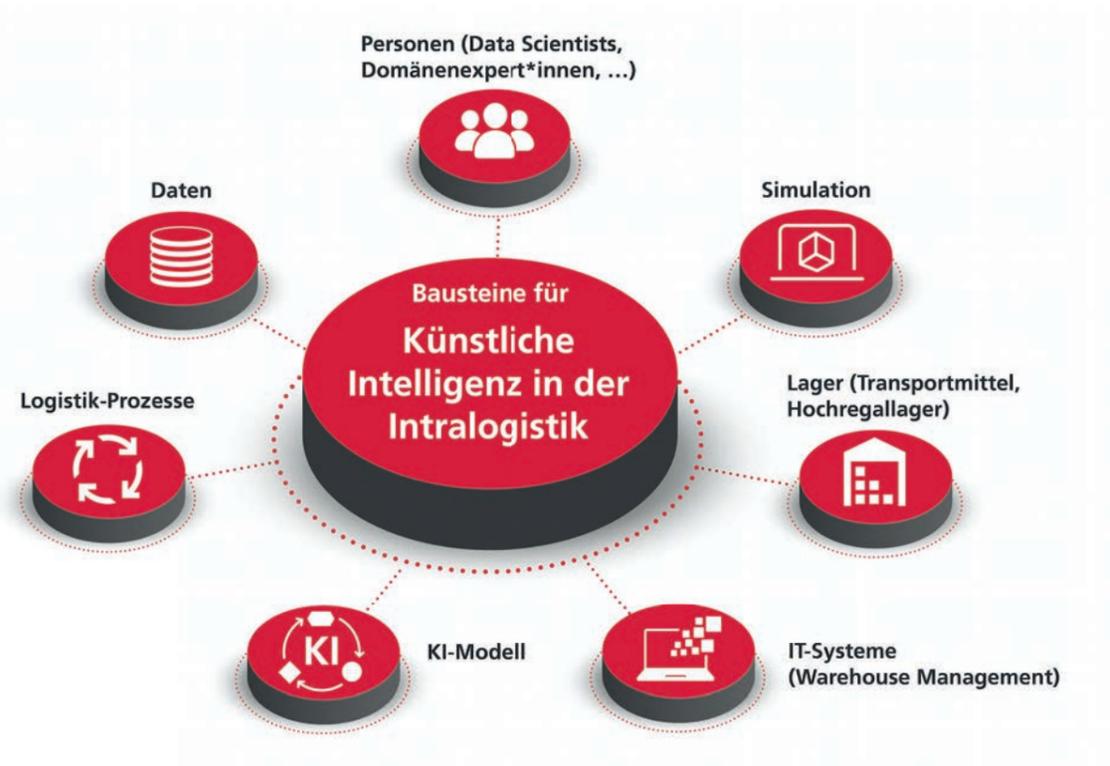


Herzstück der Lösung ist ein datengetriebenes Modell, an dem Miele und das Fraunhofer IEM derzeit arbeiten. Für die Erstellung dieses Modells werden verschiedene Daten aus dem Lager, wie etwa Transportaufträge oder die aktuelle Lagerbelegung, benötigt. Auch künftig werden kontinuierlich neue Daten eingespeist, die das Modell noch besser und zuverlässiger machen.

Wie genau arbeitet das Projektteam an diesem Modell? Grundlage der Zusammenarbeit ist ein gemeinsames Verständnis des Anwendungsfalls und der einzelnen Prozesse im Lager. In einem Grobkonzept für die KI-Lösung entsteht ein „Bauplan“ für die Programmierung. Dabei wird erarbeitet, welche Daten aus dem Lager bereits heute vorliegen und welche Kennzahlen zusätzlich und auf welchem Wege ermittelt werden können. Alle Daten müssen vorverarbeitet werden: sie werden sortiert und auf ihren Inhalt geprüft. Fehlerhafte Daten werden

assortiert. Anschließend wird das Modell erstellt. Des- sen Kern sind verschiedene Regeln, die zuvor gemein- sam erarbeitet wurden. Die Kombination dieser Regeln führt zu einer nachvollziehbaren und verlässlichen Platz- zuweisung für neu angelieferte Materialien. Die Evalu- ation des Modells erfolgte über eine Simulation. Diese wurde von den Logistikexperten von Miele erstellt und ermöglicht es, verschiedene Szenarien durchzuspielen. Mit Vergangenheitsdaten wurden dabei die Wege zu den tatsächlichen Lagerplätzen und die zu den optimierten Lagerplätzen verglichen. Insgesamt ergab sich eine er- rechnete Verkürzung der gefahrenen Wege um minde- stens 7%, was neben Miele's Logistikern sicherlich auch die Umwelt freuen dürfte. Derzeit wird das Modell in die Anwendung gebracht: Es soll eine Schnittstelle zum be- stehenden ERP-System geschaffen werden. Angestrebt ist hierbei, dass das Modell über Nacht läuft und somit tagesaktuelle Informationen in das System lädt. Dieses

Im it's OWL Projekt 'IMAGINE' arbeiten das Fraunhofer IEM und Miele, Werk Oelde an einer Lösung zur Optimierung des Hochregallagers.



nutzt die Informationen, um bei der Anlieferung neuer Materialien einen optimalen Lagerplatz vorzuschlagen. Da das Modell im Hintergrund arbeitet ändert sich an den Arbeitsabläufen im Lager nichts.

Der grundlegende Unterschied zu anderen Projekten ist, dass die Logistikexperten von Miele die Lösung selbst programmiert haben. Dafür wurde vom Fraunhofer IEM ein Vorgehensmodell¹ entwickelt, bei dem sowohl das Wissen der Experten miteinbezogen wird als auch Fachexperten das Programmieren lernen. Diese Fachexperten, deren Aufgabengebiet außerhalb der Analyse von Daten liegt, die aber zeitweise Aufgaben der Datenanalyse übernehmen, nennt Gartner „Citizen Data Scientists“². Indem die KI-Anwendung von den Logistikexperten mit entworfen und selbst programmiert wird, ist nicht nur die Akzeptanz der Lösung sichergestellt; die eigenständige Anpassung auf Prozessänderungen sichert den langfristigen Betrieb und den Transfer auf ähnliche Situationen oder weitere Werke. Eine solche Verstetigung von Data Science-Wissen im Betrieb bringt ein besseres Verständnis der eigenen Prozesse, erhöhte Flexibilität, mehr Sicherheit im Umgang mit Daten und somit einen entscheidenden Wettbewerbsvorteil mit sich.

Eine der größten Herausforderungen für die Citizen Data Scientists war, neben dem Alltagsgeschäft die notwendige Zeit für die Entwicklung aufzubringen. Gerade zu Projektbeginn war der Aufwand für die Einarbeitung sehr hoch. Es zeigt sich jedoch bereits, dass es sich gelohnt hat: Die erworbenen Kenntnisse und Fähigkeiten können auch an anderen Stellen im Unternehmen eingesetzt werden. Grundsätzlich ziehen wir ein positives (Zwischen)Fazit und resümieren, dass wir einen ähnlichen Use Case auch zukünftig so angehen würden. Was wir aktuell auch schon tun: Wir arbeiten an einer Vorhersage für die Auslastung von Ressourcen der Intralogistik für ein anderes Werk von Miele.

Quellenangabe

¹ S. Merkelbach, S. Von Enzberg, A. Kühn and R. Dumitrescu, „Towards a Process Model to Enable Domain Experts to Become Citizen Data Scientists for Industrial Applications,“ 2022 IEEE 5th International Conference on Industrial Cyber-Physical Systems (ICPS), 2022, pp. 1-6, doi: 10.1109/ICPS51978.2022.9816871.

² <https://www.gartner.com/smarterwithgartner/how-to-use-citizen-data-scientists-to-maximize-your-da-strategy>

Autorin Forschung

Silke Merkelbach ist wissenschaftliche Mitarbeiterin im Bereich Industrial Data Analytics am Fraunhofer IEM in Paderborn. Nach einem dualen Bachelor in Wirtschaftsingenieurwesen und einem Diplom in Verfahrenstechnik hat sie sich auf die Analyse industrieller Daten spezialisiert. Kern ihrer Arbeit bei Fraunhofer ist die Erforschung von Möglichkeiten, wie Expertenwissen in datengetriebene Modelle eingebracht werden kann, um Ingenieur:innen die Analyse von Daten zu erleichtern.



Autor Industrie

Henning Hallmann ist bei Miele & Cie. KG in der Business Unit Cooking im Werk Oelde als Logistikplaner tätig. Seit 2017 im Unternehmen, ist er im Rahmen seines dualen Studiums in unterschiedlichen Schnittstellenpositionen tätig gewesen und hat den Bachelor als Wirtschaftsingenieur absolviert. Im 'IMAGINE'-Projektteam ist er verantwortlich für die technische Use-Case-Umsetzung der intelligenten Platzzuweisung im Hochregallager.



EFFIZIENZSTEIGERUNG VON PRODUKTIONSPROZESSEN

MIT MASCHINELLEM LERNEN ANLAGENEFFIZIENZ UND PROZESSSICHERHEIT LANGFRISTIG GARANTIEREN

Dürfen wir vorstellen?
Der vom Fraunhofer IEM
in Kooperation mit der
Düspohl Maschinenbau
GmbH entwickelte
„RoboGrinder“

Bei vielen Unternehmen herrscht noch die dominierende Befürchtung, dass mit der Automatisierung komplexer Prozesse eine unzuverlässige „70 Prozent Lösung“ implementiert wird. Aus diesem Grund werden nach wie vor viele Arbeiten, die eine hohe Expertise erfordern, per Handarbeit ausgeführt, obwohl sie inzwischen automatisierbar wären. So auch das Schleifen von Ummantelungsrollen. Die komplex konturierten Gummirollen sind essenzielle Werkzeuge zur Profilmantelung, welche weltweit in entsprechenden Anlagen eingesetzt werden

– dabei benötigt jedes Produkt einen individuellen Satz Ummantelungsrollen. Der grundsätzliche Umrüstungsprozess der Profilmantelungsanlagen auf ein neues Produkt ist schon heute binnen weniger Minuten umsetzbar; derzeitiger Schlüsselfaktor ist der übergeordnete Herstellungsprozess der Rollen. Um die Rollen auf ein Sollmaß zu schleifen, muss das komplexe Materialverhalten beherrscht werden. Hierzu entwickelt das Fraunhofer IEM in Kooperation mit der Düspohl Maschinenbau GmbH den „RoboGrinder“. Dieser soll zukünftig eine bedarfsgerechte

Produktion beim Kunden vor Ort gewährleisten. Dazu automatisiert der „RoboGrinder“ erstmalig die Konturregelung mit einem Roboter durch eine vertrauenswürdige Komposition aus konventioneller Regelungstechnik und Methoden des maschinellen Lernens, welche die Anlageneffizienz und Prozesssicherheit dauerhaft sicherstellt.

Der „RoboGrinder“ setzt auf eine Roboter-gestützte Automatisierung, welche die Effizienz des Schleifprozesses deutlich steigert, reproduzierbare Ergebnisse sicherstellt und eine bedarfsgerechte Produktion mit Losgröße Eins ermöglicht. Durch den Einsatz einer KI-Korrektur verbessert sich die Konturregelung fortlaufend und spart mit dem hybriden Ansatz Schleifiterationen ein. Die KI erhält dazu den Fehler zwischen Soll und Ist-Kontur sowie weitere Prozessparameter als Eingang und nimmt auf Basis dieser eine Korrektur vor. Dadurch können 15% der gesamten Schleifdurchläufe gegenüber der Fertigung mit einer konventionellen Regelung eingespart werden. Beim Nachschleifen von gebrauchten Rollen, bei dem besonders sensibel und genau gearbeitet werden muss, sind es bis zu 40%. Durch die installierte Sensorik erkennt das System die Ist-Kontur der Ummantelungsrolle eigenständig und konfiguriert den Bearbeitungsprozess automatisch. Die Bausteine der konventionellen Regelungstechnik fungieren dabei als eine Art Leitplanke, die die optimierte Lösung der KI in den technisch realisierbaren Rahmen einfügt. Dadurch kann der sichere Betrieb der KI gewährleistet werden. Auch die Rüstzeit wird durch die Kombination aus KI und Regelungstechnik deutlich optimiert: Von der Planung bis zur Fertigstellung dauert es im Durchschnitt nur noch wenige Minuten. Binnen eines Jahres konnte der Weg hin zum vertrauenswürdigen KI-Schleifsystem durch einen schlanken, agilen Entwicklungsprozess und unter Nutzung eines digitalen Zwillings, sowie modellbasierten Eigenschaftsabsicherungen realisiert werden. Das Training der KI konnte bereits frühzeitig auf die Daten des digitalen Zwillings zurückgreifen, weshalb die Lösungsfunktionalität schon in einem frühen Entwicklungsstadium verifiziert werden konnte.

Die synthetischen Daten erlaubten darüber hinaus eine beschleunigte Implementierung des Schleifsystems auf der realen Anlage, da auf ein zeit- und kostenintensives Generieren von realen Daten verzichtet werden kann. Die synthetischen Daten werden anschließend im Anlagenbetrieb durch reale Daten fortlaufend ersetzt. Dieses Online-Training bietet den Vorteil, dass sich die Anlage ununterbrochen auf veränderte Betriebsbedingungen, wie zunehmenden Verschleiß, einstellen und somit dynamisch entlang realer Gegebenheiten agieren kann.

Der „RoboGrinder“ steht nur stellvertretend für ein System, mit dem wir in der Lage sind, einen Prozess unter Zuhilfenahme von KI zu automatisieren, den wir heute noch nicht vollständig oder nur durch intensiven Einsatz von Ressourcen verstehen. Er zeigt, dass Prozessautomatisierungen trotz hoher Aufgabenkomplexität und Prozessindividualität mithilfe von KI realisierbar sind. Somit ergibt sich eine Vielzahl verschiedenster Anwendungsgebiete für all jene industriellen Prozesse, die sich durch komplexes Materialverhalten, eine individuelle Handhabung oder einen hohen Bedarf an menschlicher Expertise auszeichnen.

Autor Forschung

Steven Koppert ist wissenschaftlicher Mitarbeiter und Doktorand am Fraunhofer-Institut für Entwurfstechnik Mechatronik IEM in Paderborn und leitet die Gruppe Trusted Machine Intelligence. Sein Forschungsgebiet ist Intelligente Regelungstechnik und erklärbare künstliche Intelligenz. Mit seinem Team konzentriert er sich darauf, Methoden der Ingenieurwissenschaften und der künstlichen Intelligenz zu kombinieren, um selbstlernende mechatronische Systeme zu schaffen, die besonders vertrauenswürdig und verständlich sind.



KI-GESTÜTZTE PROZESSÜBERWACHUNG

ANOMALIEN UND ÜBERBELASTUNGEN ERKENNEN

Moderne Ansätze zur Überwachung von industriellen Prozessen stützen sich immer mehr auf KI-Methoden und speziell auf Technologien des maschinellen Lernens. Dabei liefern Teilkomponenten, wie elektrische Antriebe, Signale, die das Verhalten von Maschinen und Prozessen indirekt beschreiben. Komponentenhersteller kennen oft nicht die Prozesse, für die ihre Produkte bestimmt sind. Ein Beispiel hierfür sind Elektromotoren, die in allen industriellen Prozessen eingesetzt werden. Dabei wird ein Großteil der Motoren, entsprechend des Prozesses, zyklisch genutzt. Antriebsprozesse wiederholen sich immer auf die gleiche Art und Weise und können somit genutzt werden um die typische Anwendung zu charakterisieren. Es besteht demnach die Herausforderung, einen fehlerfreien Betrieb datengetrieben zu definieren.

Im Innovationsprojekt „Maschinelles Lernen für die Produktion und ihre Produkte“ („ML4Pro²“) des Spitzenclusters it's OWL wurde durch die Partner Lenze SE und das Fraunhofer IOSB-INA eine Vorverarbeitungslösung entwi-

ckelt. Diese Lösung wurde in die Toolbox des Projektes integriert und dient als Grundlage für Systeme zur Erkennung von Anomalien. Grundlage für diese Lösung war ein Transportsystem der Firma Lenze (siehe Abbildung) welches als Demonstrator als Ergebnis des Projektes zur Verfügung steht. Die „Modulare Förderstrecke“ dient als Beispiel für einen Intralogistik-Prozess, in dem nur die Motorströme erfasst werden können. Hierüber lassen sich Belastungen und Muster in den Daten automatisch erkennen.

Aufbauend auf der erkannten Basis an Mustern in den Daten lassen sich Anomalieerkennungssysteme nutzen und aktuelle Belastungsmuster der Komponenten mit bekannten Mustern vergleichen. Dies gewährleistet analytische Mehrwerte. Die Auslastung von Förderstrecken lässt sich so berechnen und eventuelle Überbelastungen können erkannt und mit realen Anforderungen in Einklang gebracht werden. Darüber hinaus lassen sich Beratungsleistungen für die Betreiber der Intralogistikanlagen ableiten.

Demonstrator: „Modulare Förderstrecke“ der Firma Lenze SE. Alle Testaufnahmen wurden mit diesem Demonstrator durchgeführt



Autor Forschung

Jens Eickmeyer ist wissenschaftlicher Mitarbeiter im Bereich maschinelle Intelligenz am Fraunhofer IOSB-INA in Lemgo. Nach dem Studium der naturwissenschaftlichen Informatik an der Universität Bielefeld spezialisierte er sich auf die Analyse industrieller Daten am Fraunhofer IOSB-INA. Hier liegt sein Schwerpunkt auf der Erschließung von Anwendungsfällen in der Industrie, sowie der Datenvorverarbeitung, Modellierung und dem Erstellen von Architekturen für z.B. datengetriebene Zustandsüberwachungen.



CONDITION MONITORING

KRITISCHE MASCHINENZUSTÄNDE VORZEITIG ERKENNEN

Viele Produkte bei Weidmüller, wie etwa Reihenklempen oder Steckverbindungen, durchlaufen als wesentlichen Prozess in der Fertigung Galvanikanlagen zur Oberflächenbehandlung von Metallen. Zur Verbesserung der elektrischen und mechanischen Eigenschaften durchläuft ein Metallband dabei eine Vielzahl an Becken, in denen es mit entsprechenden Chemikalien umspült und durch elektrochemische Prozesse beschichtet wird. Das Umspülen erfolgt durch Pumpen, die unterhalb der Becken angebracht sind und aufgrund der eingesetzten, aggressiven Chemikalien einem erhöhten Verschleiß unterworfen sind. Dabei sind sie ein entscheidendes Element für eine störfreie Produktion, kann der Wegfall einer Pumpe unter Umständen zu einem Ausfall eines Beckens und damit zum Stillstand der gesamten Anlage, sowie der Verschrottung des Metallbandes führen.

In diesem Use-Case sollten Verfahren entwickelt werden, die eine kontinuierliche Überwachung (Condition Monitoring) sowie eine bedarfsgerechte und planbare Wartung der Pumpen (Predictive Maintenance) ermögli-

chen. Dazu wurden in einem Teil einer Produktivanlage Pumpen mit passender Sensorik zur Erfassung relevanter Maschinen- und Prozessparameter ausgestattet. Es werden Messdaten wie Vibration, Temperatur, elektrische Leistungsaufnahme, Akustik oder Durchfluss kontinuierlich erfasst und zur Systemanalyse zur Verfügung gestellt.

Eine Analyse und Bewertung des Pumpenzustandes und der Prozessqualität können nur aus der Gesamtheit der eingesetzten Sensorik heraus erfolgen. Hierzu wurden für den Use-Case Ansätze des maschinellen Lernens (ML) transferiert und weiterentwickelt, die auch komplexe und unbekannte kausale Zusammenhänge der Pumpenanlage automatisiert lernen und wiedergeben können. So eignet sich bereits ein Naiver-Bayes-Klassifikator als etabliertes ML-Verfahren, um kritische und künftige, potenziell kritische Maschinenzustände zu klassifizieren. Allerdings stellt der Einsatz von Säuren und Laugen in der Galvanik besondere Herausforderungen an die eingesetzte Sensorik dar. Intelligente Algorithmen müssen in der Lage sein, Sensorausfälle und -verschleiß zu kompensieren. Um die



Wichtiges Element in der Produktion bei Weidmüller: Die Galvanikanlagen.

Robustheit der ML-Verfahren zu erhöhen, werden deswegen Methoden der Informationsfusion (IFU) angewendet. Durch die Fusion teilerdunder Informationen wird der Einfluss von Verschleißeffekten auf die Leistung der eingesetzten ML-Methoden reduziert. IFU-Methoden bergen den zusätzlichen Vorteil, dass auch Anwendungsfälle, in denen viele Datenquellen, aber prinzipiell wenig Daten (Scarce Data, Small Data) zur Verfügung stehen, für maschinelle Lerner nutzbar gemacht werden.

In der konkreten Umsetzungsphase und der Datenaufnahme an der Produktivanlage stellte sich heraus, dass hauptsächlich große Mengen an Gut-Daten angefallen sind. Daten spezifischer Fehlerfälle hingegen ließen sich nur schwer oder aufwändig produzieren - diese eingeschränkte Verfügbarkeit von Daten erschwert es maschinellem Lernen, bevorstehende Ausfälle von Pumpen vorherzusagen. Ergo war es notwendig, ein umfassendes Datenbild zu generieren, weswegen ein realistischer Pumpenprüfstand, mit dem wirklichkeitsnahe Schadensfälle reproduzierbar nachgestellt und sensorisch erfasst werden konnten.

Erste Arbeiten im Use-Case fokussierten sich auf die Motordrehzahl als Indikator für sich ankündigende Fehlerfälle. Bei dem Pumpenmotor handelt es sich um einen unregelmäßigen Motor, d.h. die Drehzahl des Motors wird durch die Schwankungen der Netzfrequenz beeinflusst. Weil der Einfluss von Fehlerfällen auf die Drehzahl des Motors teilweise geringer ist als die durch Netzfrequenzschwankungen verursachten Drehzahländerungen, ist es allerdings nicht möglich, die Fehlererkennung alleine auf die Motordrehzahl zu stützen. Der Pumpenprüfstand wurde deswegen multi-sensorisch ausgelegt, um aussagekräftige Merkmale nutzen und fusionieren zu können.

Neben der Herausforderung, geeignete Merkmale zu finden, die ein Indikator für einen Fehlerfall des Motors sind, müssen die ML- und IFU-Methoden robust und skalierbar vom demonstrativen Einsatz in den produktiven Prozess überführt werden können. Die Einzelkomponenten der Pumpen unterliegen hersteller- und alterungsbedingten Varianzen, die im langfristigen Einsatz berücksichtigt werden müssen. Damit hier geeignete Lösungen entwickelt werden können, muss der Einfluss der Pumpenvarianz auf die entwickelten Merkmale untersucht werden. In der Regel müssen Maßnahmen ergriffen werden, um den Algorithmus zu kalibrieren und angemessen auf Langzeitdrift reagieren zu können.

Die im Use-Case der Galvanikanlage entwickelten Methoden des maschinellen Lernens und der Informationsfusion wurden in der Projektlaufzeit vollständig in Python demonstrativ umgesetzt. Die Datenverarbeitung wurde dabei modularisiert und in einzelne Lösungsbausteine überführt und der im Rahmen des Gesamtprojektes ML4Pro² (ml4proflow) erarbeiteten ML-Toolbox zur Verfügung gestellt. So können die Module zur Überwachung der Pumpen mit weiteren Lösungsbausteinen aus anderen Quellen frei kombiniert und jederzeit erweitert werden, um sich realen Gegebenheiten dynamisch anzupassen. Zum Beispiel können MQTT-Bausteine integriert werden, um die Daten des Pumpenprüfstandes direkt über MQTT in der Toolbox zu empfangen. Die Ausgaben der ML-Methoden über Wartungsprognosen und Handlungsempfehlungen werden in einem Dashboard interaktiv aufbereitet und dem Nutzer so einfach zugänglich gemacht.

Der im Use-Case entwickelte Messaufbau soll in weiteren geplanten Arbeiten für andere Pumpen der Produktivanlage adaptiert werden, um die Methoden auf Skalierbarkeit und Übertragbarkeit zu untersuchen.

Autor Forschung

Malte Schmidt war während des Projekts wissenschaftlicher Mitarbeiter am Institut für industrielle Informationstechnik der Technischen Hochschule Ostwestfalen-Lippe.

Er beschäftigt sich mit Informationsfusion und maschinellem Lernen für vorausschauende Instandhaltung (Predictive Maintenance) von Industrieanlagen.



Autor Industrie

Alexander Boschmann ist Technologieentwickler bei Weidmüller und dort im Bereich Entwicklung innovativer Funktionen und neuer Technologien für die zukünftige Automatisierungstechnik tätig. Er leitet Forschungs- und Technologieentwicklungsprojekte in den Bereichen Flexible Automation, Industrial IoT und Condition Monitoring und arbeitet dabei eng mit Hochschulen und Forschungsinstituten zusammen.



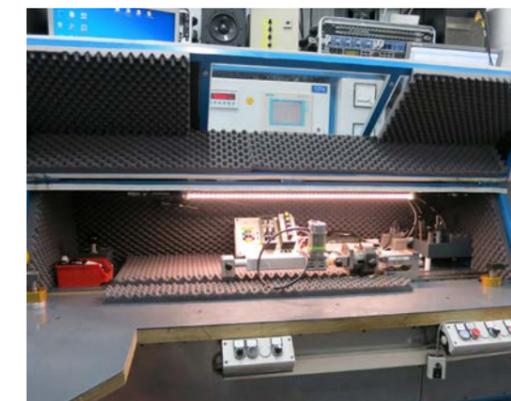
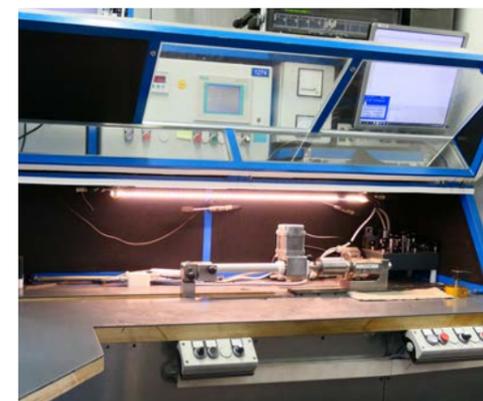
KI AUF DEM PRÜFSTAND STÖRGERÄUSCHE IN STELLANTRIEBEN REDUZIEREN

Die Firma Hanning Elektro-Werke GmbH und Co. KG fertigt unter anderem Verstellantriebe für die Anwendung in der Medizintechnik, einer Branche mit besonderen Anforderungen und Qualitätsstandards. Um den Mensch während des späteren Betriebes nicht zu stören, ist die Geräteakustik ein wichtiges Thema der Branche. Im Rahmen des Fertigungsprozesses wird daher das Geräuschverhalten jedes Antriebs in einem Prüfstand, welcher sich in einer schallisolierten Prüfkabine befindet, auf die Produktqualität bzw. Produktmängel durch eine:n Mitarbeiter:in untersucht und zusätzlich über Mikrofone aufgezeichnet. Die Auswertung dieses Prozesses obliegt Mitarbeiter:innen und somit immer einer gewissen Subjektivität. Ziel dieses Use-Cases ist es, die Akustikdaten mittels maschineller Lernverfahren in eine objektivierbare Bewertung zu überführen. Den Objektivitätsgrad zu erhöhen, bedeutet sowohl auf Kunden-, als auch auf Unternehmensseite reale Mehrwerte, denn einerseits können Kundenanfragen präziser erfüllt und andererseits Reparatur- und Prüfzeiten gesenkt und somit Kosten reduziert werden.

Um dies zu realisieren, musste in einem ersten Schritt ein Datensatz von aufgezeichneten Verstellantrieben inklusive deren Bewertung erstellt werden. Dazu wur-

den alle Antriebe eines ausgewählten Zeitraums von vier Experten angehört und nach Qualität bewertet. Parallel dazu wurden Datenvorverarbeitungsschritte und Merkmale für die zu bewertenden akustischen Daten recherchiert, exploriert und evaluiert³. In dem Hanning Use-Case lieferten Merkmale aus dem Bereich Representation Learning through Deep Learning (RLDL) die besten Ergebnisse. Dabei wird die Transformation von Rohdaten zu Merkmalen durch ein tiefes neuronales Netz datengetrieben erlernt. Bedingt durch die Diskrepanz, dass beim RLDL mehr Daten zum Trainieren des Modells benötigt werden, als Verstellantriebsdaten zur Verfügung standen, wurde das Modell zusätzlich mit branchenfremden Daten trainiert. Hier zeigte sich in Experimenten, dass gelernte akustische Musik-Merkmale auch in der Verstellantriebsdomäne erfolgreich eingesetzt werden können. Die diagnostizierte Anfälligkeit der erarbeiteten Merkmale gegenüber akustischen Störgeräuschen, konnte durch den schallgedämmten Prüfstand entgegengewirkt werden.

Nachdem die Akustikdaten zu Merkmalen transformiert wurden, galt es basierend darauf, einen Antrieb als bestanden oder nicht bestanden zu bewerten. Dazu wurde ein One-Class-Classifier (OCC) aus der halbüberwachten



Der Prüfstand früher und heute: Die Schalldämmung hilft Störgeräusche zu eliminieren

Anomalieerkennung genutzt. Ein OCC wird auf einer Klasse trainiert und prognostiziert eingehende Merkmale als zur trainierten Klasse zugehörig oder nicht. Zudem können im Verbund (engl. Ensemble of OCC) auch mehrere Klassen abgebildet werden. In der produzierenden Industrie sind häufig zu Beginn von Datensammlungen für ML sehr viele Daten im Gut-Zustand verfügbar, da die Produktionsprozesse durch jahrzehntelange Verbesserungen und Erfahrungen stabil am optimalen Arbeitspunkt liegen. Ein Vorteil von OCC ist dabei, dass die Klasse des Gut-Zustands früh trainiert und in den Prozess eingebunden werden kann. Von der OCC abgelehnte Daten können nachfolgend gezielt analysiert und in einen neuen Datensatz einer Klasse (z.B. Schaden A) überführt werden. Sobald genügend Daten zum Trainieren verfügbar sind, kann dieser OCC in den OCC-Verbund eingebunden werden. Somit ist es nicht zwingend notwendig, Daten jeder denkbaren Klasse künstlich zu erstellen. Dies schont zu nutzende Ressourcen und schafft zudem ein flexibles System, welches über die Zeit anpassungsfähig bleibt.

Abschließend wurde ein Experiment entworfen, um den erarbeiteten ML-Workflow validieren zu können. Dafür wurde eine Hyperparameteroptimierung mit nachfolgender verschachtelter Kreuzvalidierung zum Betrachten verschiedener Datenverteilungen angewendet. Gegenstand der Untersuchung ist dabei ein OCC gewesen, welcher auf bestandenen Antrieben trainiert wurde und im Test bestandene Antriebe erkennen und nicht bestandene Antriebe ablehnen sollte. Die Erkennungsrate von bestandenen Antrieben erreichte $84,6\% \pm 14,9\%$ bei einer Ablehnungsrate von $81,5\% \pm 3,4\%$ bei nicht bestandenen Antrieben. Aus Sicht der Forschung und der

Industrie sind dies gute Ergebnisse, da sie große Effizienzsteigerungen in der Produktion aufzeigen. Zudem ist durch Optimieren des ML-Workflows mit besseren Ergebnissen zu rechnen.

Anfängliche Herausforderung war das Datenhandling (Erarbeiten/Einführen von Datenstruktur und Dateninfrastruktur) und die sich daraus ergebenden Änderungen am Prüfstand und Prüfablauf. Um den Transfer von einem werkerorientierten System zu einem ML-basierten Assistentensystem zu vollziehen, muss das Datenhandling weiter optimiert und der Prüfstand angepasst werden. Zudem sollte eine angepasste interne Cloud-Plattform erarbeitet werden, damit ML-Workflows über alle Prüfstände effizient skaliert werden können. Beim Explorieren der Akustikdaten zeigte sich, dass die Prüfkabine von außen einwirkende Störgeräusche zwar erfolgreich unterdrücken kann, nicht aber die innerhalb der Prüfkabine, welche noch detektiert und behoben werden mussten.

Ein Projekt Learning ist, dass gut dokumentierte, organisierte und vorverarbeitete Daten essenziell für die erfolgreiche Erarbeitung und Anwendung von ML-Workflows in der Industrie sind. Daten sind das Öl des 21ten Jahrhunderts. Doch wie auch bei Öl müssen die Daten erst „raffiniert“ werden, damit ihr volles Nutzungspotenzial verfügbar ist.

Quellenangabe

³ Wissbrock, Peter, David Pelkmann, and Björn Tölle. „Automate Quality Prediction in an End-of-Line Test of a Highly Variant Production of Geared Motors—Discussion of a Full Concept.“ PHM Society European Conference. Vol. 6. No. 1. 2021

Autor Forschung

David Pelkmann ist wissenschaftlicher Mitarbeiter im Bereich des maschinellen Lernens für industrielle Anwendungen an der Fachhochschule Bielefeld und studiert derzeit für seinen M.Eng. in digitale Technologien. Seine Forschungsinteressen im industriellen Umfeld sind akustische Qualitäts- und Zustandsbeurteilung von Maschinen, Lernen auf Datenströmen und Dokumenten-Retrieval-Systeme.



Autor Industrie

Yasin Erkul ist Entwicklungsingenieur bei Hanning Elektro-Werke in Oerlinghausen. Er absolvierte an der Ruhr-Universität Bochum seinen B.Sc. in Elektro- und Informationstechnik und vertiefte sich im Master in Automatisierungstechnik und Prozessinformatik. Zu seinen Aufgabengebieten gehören die hardwarenahe Softwareentwicklung sowie die Umsetzung von elektrischen Antriebsapplikationen und systemtechnischen Anforderungen.

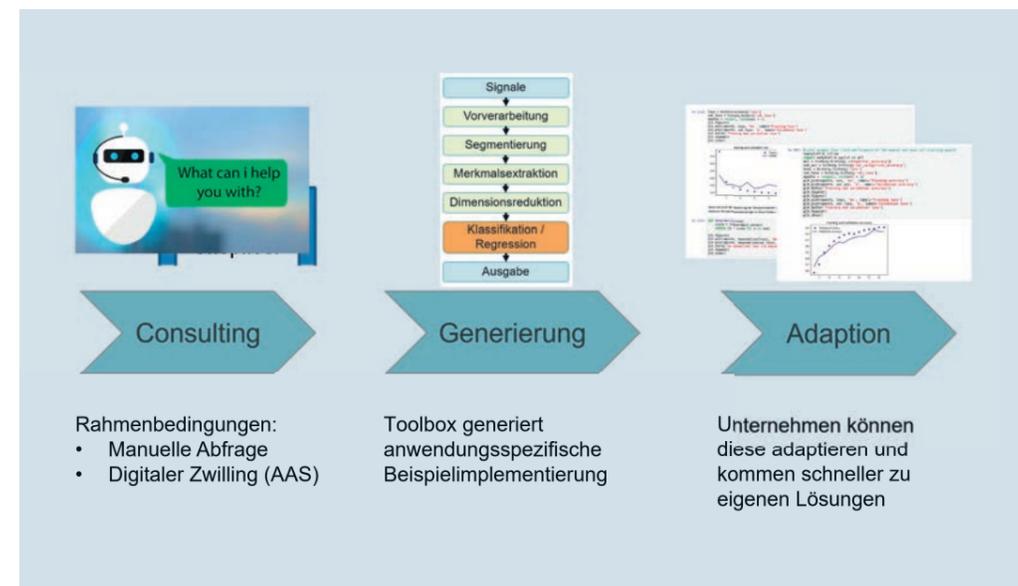


AUSBLICK: DIE ML-TOOLBOX ML4PROFLOW

MOTIVATION

Der Transfer von ML-Lösungen in den laufenden Produktionsprozess stellt nach wie vor eine große Herausforderung für die Unternehmen dar. Um die Anwendbarkeit von ML-Lösungen zu erhöhen wurde im Projekt „ML4Pro“ ein dreistufiger Prozess (s. Abb. unten) definiert. Im Verlauf des Projekts wurden diese Schritte mit der Entwicklung der ML4ProFlow Toolbox umgesetzt. Durch ein vereinfachtes Consulting und zusätzlichen Wissenstransfer über die verantwortlichen Entwickler:innen hinaus wird so der Anwenderkreis für die ML-Methoden vergrößert. Die Toolbox hat das Ziel, die entwickelten Methoden und Verfahren in ihrer Struktur zu vereinheitlichen, so dass eine computergestützte Generierung von Beispiellösungen ermöglicht wird. Während der Bearbeitung des

Projekts „ML4Pro“ konnte eine einheitliche Struktur für die ML-Lösungen der einzelnen Use-Cases ausgearbeitet werden. Diese Verallgemeinerung der Prozesskette nutzt die ML-Toolbox aus, indem eine geeignete Modularisierung abgeleitet wird. Dies verhindert die Entwicklung verschiedener isolierter Einzellösungen und ermöglicht die Wiederverwendbarkeit einzelner Anwendungen innerhalb und außerhalb des Projekts. Zudem sollte mit der ML-Toolbox keine alleinstehende Sammlung an vereinheitlichten Methoden entstehen, sondern ein Framework, welches die Möglichkeit bietet, sich an bisherige industrielle Standards anzubinden. Dieses ermöglicht eine einfache Adaption der Prozesskette an die bestehende Infrastruktur in den Unternehmen.



Notwendige Schritte zur Integration von ML-Lösungen

HERAUSFORDERUNGEN

Durch eine Anforderungsanalyse zu Beginn des Projekts konnten wichtige Aspekte für die technische Umsetzung definiert werden. In Tabelle 1 sind die Ergebnisse der Umfrage innerhalb des Konsortiums dargestellt.

Die Kernaspekte der Anforderungsanalyse stellen die wesentlichen Herausforderungen in der technischen Umsetzung dar. Das Framework soll modular und erweiterbar bleiben, gleichzeitig jedoch zur Lösung spezifischer Problemstellungen angepasst werden können. Dabei ist ein wesentlicher Aspekt die Integration der entwickelten ML-Verfahren und die Kombination dieser durch die Beschreibung geeigneter Schnittstellen. Diese müssen moduleinheitlich integriert werden und somit modulübergreifend und modulunabhängig die Datenübertragung entlang der

jeweiligen Prozessschritten, dem sog. Datenverarbeitungsgraph, ermöglichen.

Weiterhin wird aus den Ergebnissen der Umfrage deutlich, dass die Toolbox sowohl als Entwicklungswerkzeug für ML-Methoden, als auch für die Datenanalyse direkt an den Produktionssystemen angewendet werden soll. Die Nutzer:innen der Toolbox stammen dabei aus einem breiten Anwenderfeld. Die Komplexität für die Anwendung der ML-Toolbox als auch für die Entwicklung neuer Verfahren sollte daher möglichst niederschwellig gehalten werden. Weiterhin ist für die Anwendung der Toolbox sicherzustellen, dass eine einfache Anbindung an die heterogenen Soft- und Hardwarestandards der Unternehmen gegeben ist.

Ergebnisse der Anforderungsanalyse (Tabelle 1)

Besonders wichtige Aspekte	Industriepartner	Hochschulpartner
Modularität und Erweiterbarkeit	4,8 / 5	4,3 / 5
Integration von ML-Funktionen	4,6 / 5	4,2 / 5
Beschreibung von Schnittstellen	4,4 / 5	4,2 / 5

Die Toolbox soll...	Industriepartner	Hochschulpartner
... ein Entwicklungswerkzeug sein.	4,4 / 5	3,7 / 5
... zur Datenanalyse verwendet werden.	4,0 / 5	3,8 / 5
... über die Projektlaufzeit hinaus weiterentwickelt werden	4,0 / 5	3,7 / 5

UMSETZUNG

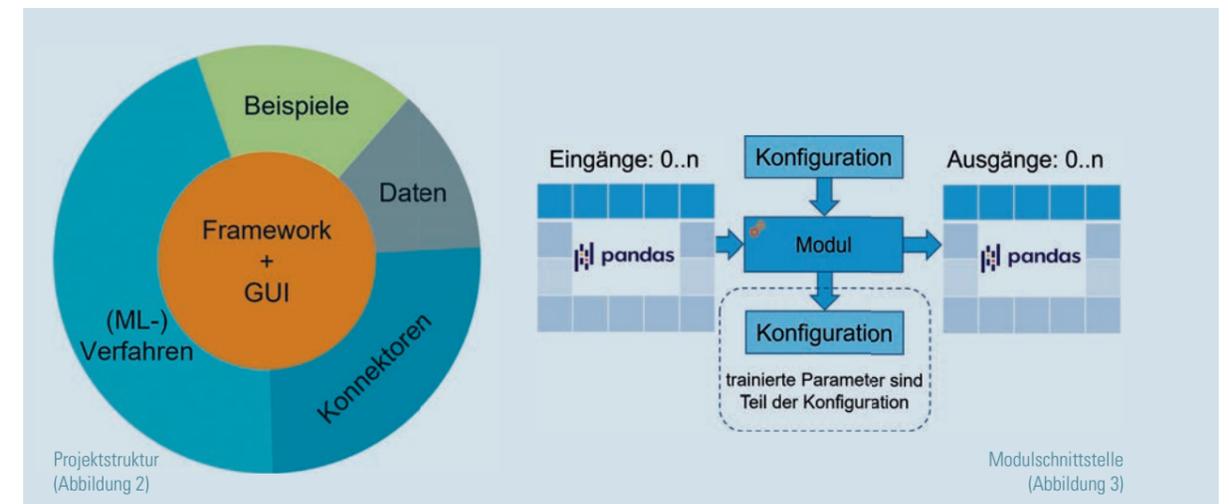
Durch eine erste Analyse der einzelnen Use-Cases konnten die Anforderungen an die interne Kommunikationsstruktur herausgearbeitet werden. Das Datenformat musste eine Vielzahl von Datentypen unterstützen, sowie die Möglichkeit des Transportes von Metadaten bieten. Daher wurde frühzeitig auf Dataframes des Frameworks Pandas als internes Datenformat gesetzt. Auf dieser Basis wurde die erste Integrationsrunde gestartet, in der die Verarbeitungsketten des ersten Use-Cases modularisiert und als einzelne Methoden in Jupyter-Notebooks implementiert wurden. Dabei konnte prototypisch schon in dem frühen Entwicklungsstand eine vereinfachte Kommunikationsstruktur realisiert werden. Mit dem Abschluss der ersten Integrationsrunde wurde eine erste Version des Frameworks inklusive einer graphischen Benutzeroberfläche vorgestellt. Zum Start der nächsten Integrationsrunde, in der die Verfahren drei weiterer Use-Cases in die vorhandene Struktur auf Basis der Jupyter-Notebooks integriert wurden, konnten weitere Entwicklungspotentiale identifiziert

werden. Es wurde unter anderem deutlich, dass das Framework Möglichkeiten für verschiedene Modi wie z.B. Datenanalyse, Training oder Online-Modus, zulassen muss. Als Folge davon wurde die Modulkonfiguration entwickelt, die alle verfahrensspezifischen Parameter beinhaltet. Dieses stellte sich als Schlüsselkonzept des Frameworks heraus. Mit der Sammlung der Verfahren wurde zudem deutlich, dass eine übergeordnete Instanz notwendig ist, die sowohl die einzelnen Module verwaltet als auch die Kommunikation zwischen den Modulen realisiert. So konnte das Kommunikationsprinzip erweitert werden, sodass eine komplexe Kommunikationsstruktur möglich wird. Durch die Integration der restlichen Use-Cases wurde die Entwicklung des Frameworks abgeschlossen und die graphische Oberfläche iterativ verbessert. Insgesamt konnte durch die vereinheitlichte Modulstruktur sowie durch die Entkoppelung von Kommunikations- und Funktionsaufgaben innerhalb der Toolbox ML4ProFlow eine erfolgreiche Modularisierung erreicht werden.

ARCHITEKTUR

ML4ProFlow ist in unabhängig installierbare Teilprojekte gegliedert. Diese sind in einzelne Python-Module verpackt, so dass sie mit Hilfe von Paketverwaltungssystemen wie z.B. PIP installiert und verwaltet werden können. Abbildung 2 gibt einen Überblick über die Projektstruktur: Im Zentrum steht das Hauptframework, welches die Schnittstellen der Module definiert. Alle Verfahren der Toolbox sind mit Hilfe der oben genannten Schnittstelle in Module verpackt und in der entsprechenden Rubrik eingeordnet. Diese Modulschnittstelle ist in Abbildung 3 dargestellt. Das Framework Pandas bildet die Basis für die Datenübergabe zwischen den Modulen. Typischerweise haben Module Ein- und Ausgänge. Es gibt jedoch auch spezielle Module. Beispielsweise hat eine Quelle keinen Eingang, jedoch beliebig viele Ausgänge. Analog dazu hat eine Senke nur Ein- und keine Ausgänge. Beispiele solcher Quellen und Senken, z.B. CSV-Datenquelle, OPC-UA, MQTT, befinden sich im Teilprojekt ml4proflow-mods-io. Module können zur Laufzeit entsprechend der An-

forderung angepasst werden, weshalb die Konfiguration der Module ein essenzieller Teil der Modulschnittstelle ist. Beispielsweise können hier prozessspezifische Parameter aber auch modulspezifische Parameter wie z.B. der Zustand (Training, Inferenz oder Fehler) hinterlegt werden. Neben der Modulrubrik können auch Versuchsdaten einheitlich veröffentlicht werden. Diese werden in der Rubrik Data zur Verfügung gestellt. Werkzeuge zur Analyse verschiedener Aspekte von einzelnen Modulen oder gesamten Verarbeitungsgraphen befinden sich in der Rubrik ml4proflow-eval. Weiteres dazu im Abschnitt Benchmarking. Datenverarbeitungsgraphen werden durch Verkettung mehrerer Module und Beschreibung ihrer Konfigurationen gebildet und somit auf den jeweiligen Use-Case individuell zugeschnitten. Um den einzelnen Nutzergruppen individuell einen einfachen Einstieg in die Toolbox zu ermöglichen, werden unterschiedliche Benutzeroberflächen angeboten. In ML4ProFlow sind deshalb Kernalgorithmen und Oberfläche getrennt.

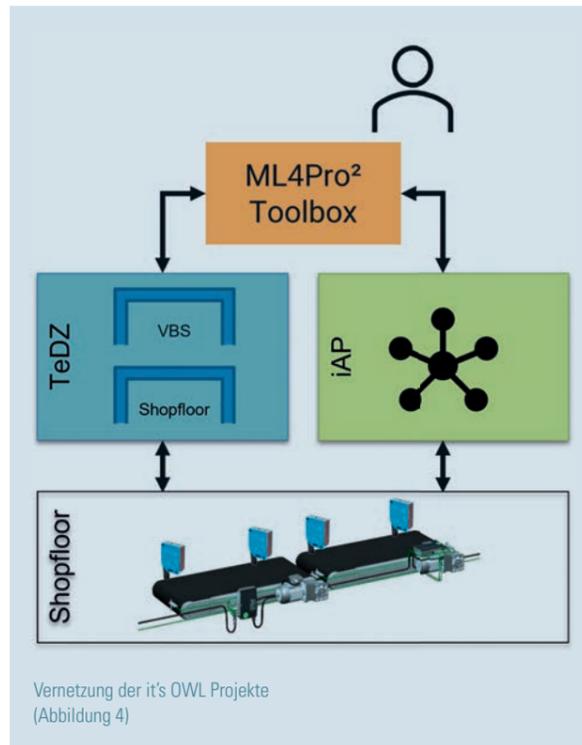


Projektstruktur (Abbildung 2)

Modulschnittstelle (Abbildung 3)

DIGITALER ZWILLING

In der Industrie 4.0 werden immer mehr Informationen über den Zustand von Produktionsmaschinen und damit auch des gesamten Produktionsprozesses digitalisiert und somit nutzbar gemacht. Es gibt jedoch eine Vielzahl an Formaten und Übertragungsprotokollen, in denen diese Daten anfallen. Weiterhin steigt die Schwierigkeit relevante Sensoren für die eigene Fragestellung zu identifizieren und geeignete Algorithmen für die Verarbeitung dieser Daten auszuwählen. Für diese Problemstellung konnte ein Mehrwert durch die Vernetzung der drei it's OWL Projekte ‚ML4Pro²‘, Technische Infrastruktur für Digitale Zwillinge („TeDZ“) und Industrial Automation Plattform für Big Data („iAP“) gezeigt werden. In dem in Abbildung 4 dargestellten Szenario einer modularen Förderstrecke ist die iAP der Datenspeicher der Toolbox und bietet eine einheitliche Schnittstelle auf die Daten der Produktionsstätte, insbesondere auch für historische Daten. Mit Hilfe von Informationen des digitalen Zwillinges (AAS) einer Produktionsmaschine kann die Toolbox identifizieren, welche Sensoren eine Maschine besitzt und wie diese über das Netzwerk abgefragt werden können. Weiterhin kann die Toolbox die Beziehungen zwischen den digitalen Zwillingen nutzen, um die Position der Maschine innerhalb des Produktionsprozesses darzustellen, da diese den Aufbau der Produktionsstätte widerspiegeln. Schlussendlich können durch einen automatisierten Abgleich der digitalen Zwillinge von Shopfloor und Toolbox Algorithmen geeignete ML-Verfahren angezeigt, ausgewählt und angewendet werden.



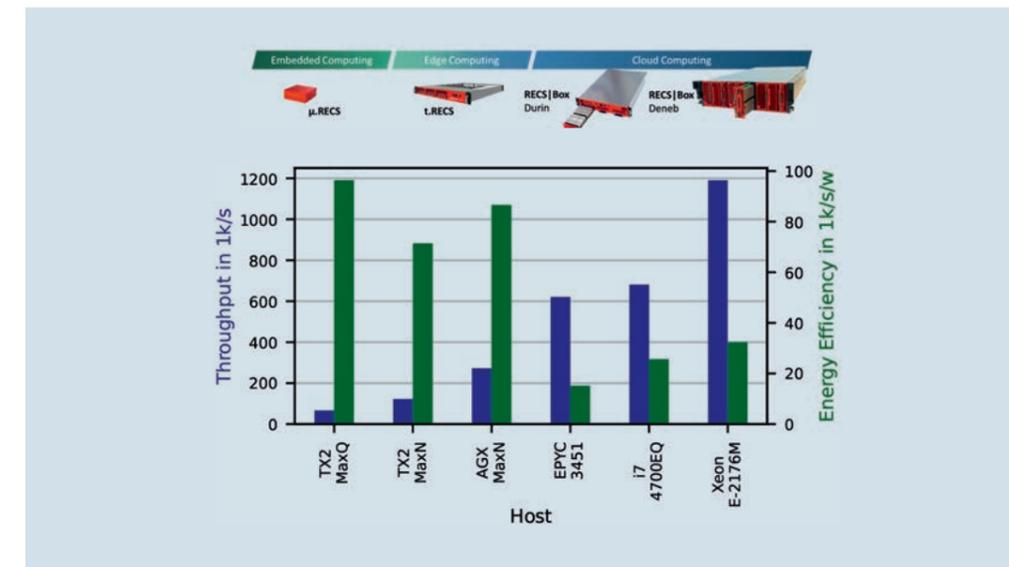
Vernetzung der it's OWL Projekte (Abbildung 4)

BENCHMARKING

ML4proflow unterstützt die Entwickler:innen zudem mit Werkzeugen zur automatischen Leistungsbewertung der Algorithmen auf verschiedenen Zielplattformen. Im Projekt wurde hierfür das RECS-System der Uni Bielefeld verwendet, welches die Einbindung unterschiedlicher Plattformen (vgl. Abbildung 5) in eine standardisierte Umgebung ermöglicht. Das RECS-System bietet hierbei die Möglichkeit, Kennzahlen wie z.B. die momentane Leistungsaufnahme, Kennzahlen wie z.B. die momentane Leistungsaufnahme der einzelnen Systeme abzufragen.

Die Toolbox ist in der Lage, beliebige Datenverarbeitungsgraphen auf einzelnen Plattformen ausführen und dabei

die Leistungsfähigkeit der Verarbeitungskette auf den unterschiedlichen Systemen zu ermitteln. Hierbei sind typischerweise drei Kennzahlen von besonderer Bedeutung. Die Latenz der Datenverarbeitung, also die Zeit die ein Datenpaket durch den Datenverarbeitungsgraph benötigt. Der Durchsatz, also die Anzahl der Datenpakete die pro Zeiteinheit durch den Graphen verarbeitet werden können und die Energieeffizienz der Verarbeitung, also die erreichte Genauigkeit in Abhängigkeit von der Leistungsaufnahme.



Plattformen des RECS-Systems und Ergebnisse einer exemplarischen Leistungsmessung (Abbildung 5)

WEITERFÜHRENDE NUTZUNG

ML4proflow wird als Forschungsplattform zur Bearbeitung von ML-Themen unter anderem in der Lehre und in den Forschungsbereichen Robotik (AMiRo) und Edge-Computing (RECS) weiterverwendet. Zudem wird die Entwicklung in verschiedenen Projekten fortgeführt. Hierbei ist besonders das it's OWL Projekt ‚I4.0AutoServ‘ mit dem Ziel der „Generierung eines Industrie 4.0 Ökosystem für den automatisierten Einsatz von datengetriebenen Services“ zu nennen, welches aus der Zusammenarbeit der drei Projekte ‚ML4Pro²‘, ‚TeDZ‘ und ‚iAP‘ entstanden ist. Kernaspekte der Weiterentwicklung sind:

- Standardisierung des automatischen Deployments auf geeignete Zielarchitekturen
- Standardisierung der automatischen Auswahl der datengetriebenen Services für Produktionssysteme

Zusätzlich ist die weiterführende Nutzung durch die Projektpartner und auch externe Nutzer:innen möglich, da das Framework und die im Projekt entstandenen ML-Methoden öffentlich über den Link <https://gitlab.ub.uni-bielefeld.de/ml4proflow> zugänglich ist. Alle dort gehosteten Projekte unterliegen einer Open-Source-Lizenz und stehen zur Benutzung, Weitergabe und Veränderung frei. Weitere Details und Ergebnisse finden Sie in der Publikation ‚ML4Pro²: A Framework for Low-Code Data Processing from Edge to Cloud in Industrial Production‘.

⁴ Klarhorst, Christian, Quirin, Dennis, Hesse, Marc, and Rückert, Ulrich. 2022. "ML4ProFlow: A Framework for Low-Code Data Processing from Edge to Cloud in Industrial Production". In 2022 IEEE 27th International Conference on Emerging Technologies and Factory Automation (ETFA), ed. IEEE. Piscataway, NJ: IEEE. <https://doi.org/10.1109/ETFA52439.2022.9921488>



Dr. Marc Hesse ist Teamleiter für das Themenfeld Kognitronik in der Arbeitsgruppe Kognitronik und Sensorik an der Universität Bielefeld. Er koordinierte das Projekt ‚ML4Pro²‘, in dessen Rahmen die Toolbox ML4ProFlow entstanden ist. Sein Forschungsschwerpunkt liegt u.a. auf dem modellbasierten Entwurf eingebetteter Systeme für ML-Anwendungen.



Christian Klarhorst ist seit 2019 wissenschaftlicher Mitarbeiter in der Arbeitsgruppe Kognitronik & Sensorik der Universität Bielefeld. Im Projekt ‚ML4Pro²‘ unterstützte er den Entwurf und die Umsetzung der ML-Toolbox. Hierbei lag sein Forschungsschwerpunkt u.a. auf der effizienten Nutzung vorhandener Hardwareressourcen von der Edge zur Cloud.



Dennis Quirin ist seit 2021 wissenschaftlicher Mitarbeiter in der Arbeitsgruppe Kognitronik & Sensorik der Universität Bielefeld. Im Projekt ‚ML4Pro²‘ unterstützte er den Entwurf und die Umsetzung der ML-Toolbox. Hierbei lag sein Forschungsschwerpunkt u.a. auf der effizienten Nutzung vorhandener Hardwareressourcen von der Edge zur Cloud.

STIMMEN DER PROJEKTPARTNER

„Welche Chancen, welche Risiken sehen Sie im Kontext KI für Ihr Unternehmen?“
Vertreter der am Projekt ‚ML4Pro‘ beteiligten Unternehmen geben Ihre Einschätzung ab.



„Durch den Einsatz von Künstlicher Intelligenz (KI) in unseren Industrial-Analytics-Lösungen ermöglichen wir unseren Kunden, Betriebsabläufe zu optimieren, die Produktqualität zu verbessern und neue Geschäftsmodelle zu erschließen. Auch in unserer eigenen Fertigung spielt KI eine immer größere Rolle, insbesondere auf dem Gebiet der vorausschauenden Instandhaltung (Predictive Maintenance) sowie bei der Optimierung der Anlagenverfügbarkeit.“ **ALEXANDER BOSCHMANN** | Weidmüller



„Haushaltsroboter agieren zukünftig in einem hohen Maß autonom. Künstliche Intelligenz wird diese Systeme noch leistungsfähiger machen.“ **DR. LEON ZIEGLER** | Miele



„Thermografische Daten und Prozessdaten werden als Teil der vorausschauenden Qualitätskontrolle eingesetzt. Ziel sei es, bereits im Vorfeld, anhand der Analyse von Prozesswärme zu wissen, ob die Pressteile der geforderten Qualität entsprechen werden – noch bevor sie den Produktionsprozess verlassen. Künftig sind wir in der Lage, im Bedarfsfall schneller zu reagieren und Produktionsparameter zu ändern. Damit ist gewährleistet, dass die Temperaturprofile der Komponenten innerhalb der Toleranz bleiben und Qualitätsverbesserungen während des laufenden Prozesses möglich werden.“

DR. DANIEL KÖCHLING | Benteler



„Dank maschineller Lernverfahren können unsere Kunden auch mit geringen Vorerfahrungen selbstständig und schnell sehr gute Ergebnisse und stabile Prozesse mit unseren Maschinen erreichen.“

DR. MATTHIAS HUNSTIG | Hesse GmbH



„Die im Bereich ITS auftretenden Herausforderungen an ML weichen aufgrund der Ansprüche an Wartbarkeit, Echtzeitfähigkeit, Zertifizierbarkeit und Privatheit zum Teil erheblich von den durch große Internetfirmen derzeit mittels ML adressierten Fragestellungen ab. Sie genügen nicht den Anforderungen hinsichtlich Nachvollziehbarkeit (Black-Box), Verlässlichkeit und Agilität, und sie sind oft angesichts hoch individualisierter Prozesse in den Unternehmen sowie eingeschränkter Rechenressourcen nicht anwendbar. Umgekehrt stellt der Einsatz von ML-Technologien in agilen Produktionsprozessen Hersteller technischer Systeme vor neue Herausforderungen: Neue Produktentwicklungs- und Engineeringansätze werden benötigt, welche Raum für Adaptivität lassen. Auch die Einführung neuer, datenbasierter Geschäftsmodelle erfordert komplexe Anpassungsprozesse. Diese überfordern Unternehmen oft, denn es sind keine standardisierten Verfahren zur erfolgreichen Kommerzialisierung von lernenden technischen Systemen verfügbar.“ **YASIN ERKUL** | Hanning Elektro Werke

it's OWL e. V.

Im it's OWL e. V. bündeln die Clusterpartner ihre Interessen. Weitere Unternehmen, wissenschaftliche Einrichtungen und wirtschaftsnahe Organisationen können beitreten.

UNTERNEHMEN



HOCHSCHULEN UND FORSCHUNGSEINRICHTUNGEN



TRANSFERPARTNER UND FÖRDERER



IMPRESSUM

Herausgeber

it's OWL Clustermanagement GmbH
Zukunftsmeile 2 | 33102 Paderborn
www.its-owl.de

Verantwortlich

Prof. Dr. Roman Dumitrescu, Günter Korder

Konzept

Wolfgang Marquardt, Christiane Schild

Redaktion

Verena Eickmann, Wolfgang Marquardt

Gestaltung

stilwechselform, Bielefeld

Bildnachweis

Fraunhofer IEM: Titelbild, S.4/5, S.13,
S. 15/16, S. 18, S.20 | it's OWL: S. 7 |
Josef Schulte GmbH: S.10 | Alfred Willich
GmbH: S.14 | Adobe Stock (233352589) :
S. 17 | Lenze SE: S. 22 | Weidmüller: S. 23 |
Hanning Elektro-Werke GmbH & Co. KG: S. 25 |
Universität Bielefeld: S. 27 – 31

Erschienen

März 2023

it's OWL Clustermanagement GmbH

Zukunftsmeile 2 | 33102 Paderborn
Tel. 05251 297370 | Fax 05251 2973790
info@its-owl.de | www.its-owl.de

Gefördert durch:

Ministerium für Wirtschaft,
Industrie, Klimaschutz und Energie
des Landes Nordrhein-Westfalen



Die Region:

OWL OstWestfalenLippe
Eine Region. Ein Wort.