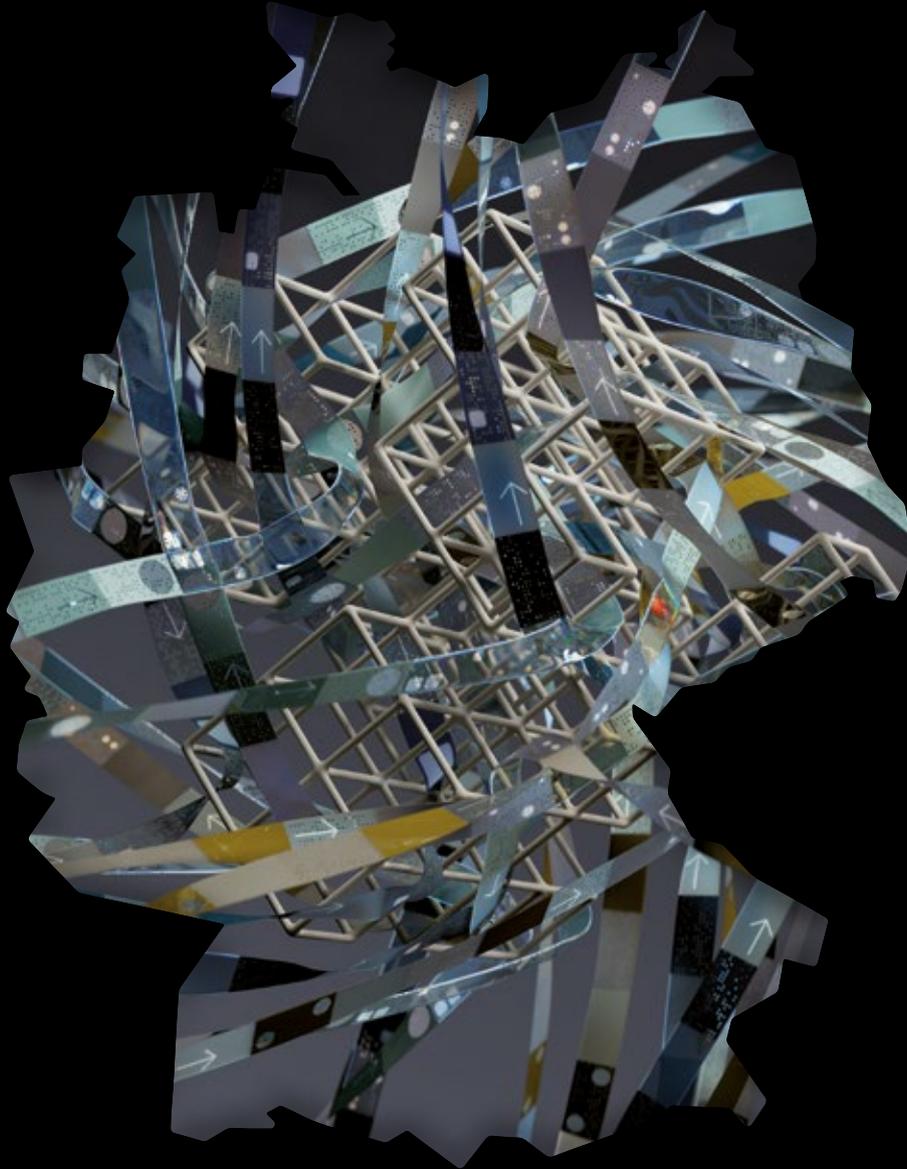




PROJEKTATLAS



KÜNSTLICHE INTELLIGENZ IN DER PRODUKTION

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung



**IN DER WISSENSCHAFT
SIND BEREITS ZAHL-
REICHE LÖSUNGEN
ERFORSCHT WORDEN,
ABER DER TRANSFER IN DIE
UNTERNEHMENSLANDSCHAFT
STELLT NACH WIE VOR EINE
HERAUSFORDERUNG DAR.**

Lukas Gründel¹, Dennis Stoppel², Sebastian Gerth³ und Nils Thielen⁴

¹ Werkzeugmaschinenlabor WZL der RWTH Aachen University, Steinbachstraße 19, 52074 Aachen

² Institut für Fertigungstechnik und Werkzeugmaschinen der Leibniz Universität Hannover, An der Universität 2, 30823 Garbsen

³ Fachgebiet Fertigungstechnik an der Fakultät für Maschinenbau an der Technischen Universität Ilmenau, Ehrenbergstraße 29, 98693 Ilmenau

⁴ Lehrstuhl für Fertigungsautomatisierung und Produktionssystematik an der Friedrich-Alexander-Universität Erlangen-Nürnberg, Fürther Str. 246b, 90429 Nürnberg



WARUM EIN PROJEKTATLAS KÜNSTLICHE INTELLIGENZ IN DER PRODUKTION?

Künstliche Intelligenz (KI) wird nicht erst seit dem Erfolg von ChatGPT des US-amerikanischen Softwareunternehmens OpenAI zu Beginn des Jahres 2023 für den Einsatz in der Produktion erforscht und gefördert. Dieser Forschungsbereich blickt auf eine lange Tradition seit den 1970er Jahren zurück^[1].

Aktuell wird insbesondere in der Qualitätskontrolle^[2-5], Prozessüberwachung^[6, 7] und der prädiktiven Instandhaltung^[8-10] am Einsatz von KI gearbeitet. Dabei erhofft man sich auch in Deutschland, Herausforderungen, wie etwa den Fachkräftemangel, Lieferketten-schwierigkeiten oder auch steigende Energiepreise, adressieren zu können^[11].

Konventionelle Ansätze, wie statistische Methoden, können dabei im Labormaßstab bereits oft von KI übertroffen werden. So werden beispielsweise neue Muster oder Zusammenhänge in den zugrundeliegenden Daten erkannt - hierzu sind traditionell gewachsene Prozesse zumeist nicht in der Lage.

Der Schritt zur tatsächlichen Umsetzung in der produzierenden Industrie ist in Einzelfällen erfolgreich. Dies unterstreicht die anhaltende Innovation, die von der Einführung von KI in bestehende Unternehmensprozesse ausgeht^[12]. Gleichzeitig zeigt es, dass in der Wissenschaft bereits zahlreiche Lösungen erforscht worden sind, aber der Transfer in die Unternehmenslandschaft nach wie vor einen Bedarf darstellt. Die nachfolgend aufgeführten Punkte spielen bei der Etablierung von KI-Technologien in den meisten kleinen und mittleren Unternehmen eine wesentliche Rolle:

- Einsatzmöglichkeiten von KI im Unternehmen
- Einschätzung des Potenzial-Ressourcen-Verhältnisses von KI-Projekten
- Zusammenspiel von Mensch und KI

Der Projektatlas adressiert diese Herausforderungen und Fragestellungen von Unternehmen mit einem „Leitfaden zur Einführung von KI“ sowie mit „KI-Lösungen aus der Praxis“. Das Literaturverzeichnis finden Sie am Ende des Leitfadens.



LEITFADEN ZUR

EINFÜHRUNG VON KI

KI-LÖSUNGEN

AUS DER PRAXIS

WIRTSCHAFTLICHER UND

STRATEGISCHER EINSATZ

DIGITALISIERUNG

72-101

DATEN

102-141

KI-METHODEN

142-189

MENSCH UND KI

190-233

PROJEKTSTECKBRIEFE

234-265



DIE „STRATEGIE KÜNSTLICHE INTELLIGENZ“ DER BUNDESREGIERUNG HAT ZUM ZIEL, DIE WETTBEWERBSFÄHIGKEIT DEUTSCHLANDS DURCH DIE ERFORSCHUNG, ENTWICKLUNG UND ANWENDUNG VON KI ZU STÄRKEN.

*Geleitwort
des Projektträgers*

(Michael Petzold)

Die Bundesregierung hat ihre „Strategie Künstliche Intelligenz (KI)“ mit dem Ziel fortgeschrieben, die Wettbewerbsfähigkeit des Wirtschaftsstandorts Deutschland durch die Erforschung, die Entwicklung und die Anwendung von KI zu stärken. Ein weiteres Ziel der Strategie ist die Verstärkung des Transfers von KI-Wissen in die Unternehmen.

Zur Erreichung dieser Ziele trägt das Bundesministerium für Bildung und Forschung (BMBF) auch mit seinen beiden Bekanntmachungen „Lernende Produktionstechnik - Einsatz Künstlicher Intelligenz (KI) in der Produktion (ProLern)“ und „Demonstrations- und Transfernetzwerk KI in der Produktion (ProKI-Netz)“ bei.



Beide Bekanntmachungen erfolgten unter dem Dach des Programms „Zukunft der Wertschöpfung - Forschung zu Produktion, Dienstleistung und Arbeit“.

Die Bekanntmachungen adressieren produzierende Unternehmen der Fertigungstechnik mit ihren Zulieferern und Dienstleistern sowie Forschungseinrichtungen mit produktionstechnischer, informationstechnischer und arbeitswissenschaftlicher Expertise.

Bedarfsgerecht individualisierte, immer komplexer werdende Produkte aus modernen Werkstoffen und ausgestattet mit neuen Funktionen, kürzer werdende Innovationszyklen, kürzere Lieferzeiten, höhere Qualitätsanforderungen, steigende Anforderungen an die Ressourcen- und Umweltgerechtigkeit, ein starker Preisdruck, der weltweite Wettbewerb, der demografische Wandel: All das und noch mehr stellen produzierende Unternehmen vor große Herausforderungen. Diesen Herausforderungen müssen die Unternehmen mit modernen Produktionsausrüstungen, mit einer exzellenten Beherrschung der Prozesse und Verfahren sowie mit ihren leistungsfähigen Mitarbeiterinnen und Mitarbeitern begegnen.

Der Künstlichen Intelligenz (KI), insbesondere dem Maschinellen Lernen (ML) wird zu Recht ein großes Potenzial unterstellt, zur Lösung der vielfältigen Aufgaben der produzierenden Unternehmen beizutragen.

Verfahren der Künstlichen Intelligenz wurden punktuell schon seit längerer Zeit erfolgreich in der Produktion genutzt. Jetzt kommt es darauf an, der KI einen breiten Zugang in das reale Produktionsumfeld zu ermöglichen. Um das zu schaffen, müssen die Chancen und Risiken des KI-Einsatzes in der Produktion bewertet und geeignete Anwendungsfelder für den KI-Einsatz identifiziert werden. Dabei kommt es darauf an, das große produktionstechnische Domänenwissen der Mitarbeiterinnen und Mitarbeiter der Unternehmen mit Unterstützung der KI zu erhalten und zu erweitern. Zudem heißt das, die KI unterstützt die Mitarbeiterinnen und Mitarbeiter bei deren Entschei-

dungsfindung und entlastet diese bei Routinearbeiten sowie bei der Verarbeitung großer Datenmengen.

Innerhalb der vierzehn vom BMBF im Rahmen der ProLern Bekanntmachung geförderten interdisziplinären Forschungs- und Entwicklungsverbundvorhaben arbeiten Vertreter aus der Industrie und der Forschungslandschaft zusammen, um reale Aufgabenstellungen aus dem Produktionsumfeld der Fertigungstechnik durch ML-Unterstützung prototypisch zu lösen. In den Verbundvorhaben wird das Domänenwissen der Fertigungstechniker mit dem informationstechnischen und arbeitswissenschaftlichen Know-how der Projektpartner zusammengeführt und dabei ein Mehrwert generiert. Methoden und Modelle der KI werden in einer produktionsnahen Anwendung weiterentwickelt und erprobt.

Die acht vom BMBF geförderten ProKI-Netz-Demonstrations- und Transferzentren widmen sich der Aufgabe, das an den beteiligten Hochschuleinrichtungen vorhandene KI-Wissen zu bündeln und den interessierten Unternehmen nahezubringen sowie diese auf dem Weg zur Einführung der KI in das Produktionsumfeld zu begleiten. Verschiedene Schulungs-, Beratungs- und Transferformate stehen zur Verfügung. Erfolgreiche Beispiellösungen vermitteln mögliche Lösungsansätze.

Die von den Projektpartnern erarbeiteten interessanten Ergebnisse, von denen einige in diesem Band vorgestellt werden, finden einen hoffentlich nachhaltigen Eingang in die industrielle Praxis, auch bei anderen Unternehmen und in weiteren Anwendungen.

Wir wünschen allen Beteiligten in der sich an die Förderung anschließenden Phase eine erfolgreiche Verwertung der erzielten Projektergebnisse. Es besteht ein großes Interesse daran, dass von den mithilfe der BMBF-Förderung erreichten und hier vorgestellten beispielhaften Projektergebnissen ein starker Impuls ausgeht, um die KI-Einführung in das reale Produktionsumfeld in vielen Unternehmen zu forcieren.



ALGORITHMEN DER KÜNSTLICHEN INTELLIGENZ WIRD EIN DISRUPTIVER CHARAKTER IN NAHEZU ALLEN BEREICHEN UNSERES BERUFLICHEN UND PRIVATEN LEBENS ZUGESCHRIEBEN.

*Geleitwort
der Redaktion*

*(Lukas Gründel,
Nils Thielen,
Dennis Stoppel,
Oliver Petrovic)*



Algorithmen der Künstlichen Intelligenz wird ein disruptiver Charakter in nahezu allen Bereichen unseres beruflichen und privaten Lebens zugeschrieben. Besonders durch die Entwicklung generativer KI in Form von Chatbots oder Bildgeneratoren wurde das Themenfeld in den vergangenen Jahren in die Mitte der Gesellschaft geholt und wird sowohl mit hohen Erwartungen als auch gewissen Ängsten verbunden. Auch in der Produktion zeigt sich der disruptive Charakter mit dem KI Prozesse verändern kann. Mithilfe lernender Systeme werden die Grenzen des Machbaren verschoben und selbst komplexe Zusammenhänge werden beherrschbar. In der Forschung wurden bereits zahlreiche Referenzprojekte durchgeführt, von denen einige auf der Website des Demonstrations- und Transfernetzwerks ProKI-Netz veröffentlicht werden. Als Konsequenz verändert sich aber auch unsere Arbeitswelt und eröffnet grundlegende Fragen, wie wir mit dieser neuen Technologie umgehen und wie wir das Zusammenspiel zwischen Mensch und KI gestalten wollen.

Vor diesen Hintergründen wurden die Themenfelder „Lernende Produktionstechnik - Einsatz Künstlicher Intelligenz in der Produktion (ProLern)“ und „Demonstrations- und Transfernetzwerk KI in der Produktion (ProKI-Netz)“ initiiert. In den insgesamt 14 Pro-Lern-Projekten werden für aktuelle produktionstechnische Herausforderungen Lösungen mithilfe von Algorithmen

der Künstlichen Intelligenz entwickelt. In den 8 ProKI-Standorten werden KI-Entwicklungen in das produzierende Gewerbe transferiert und somit Expertise in der Industrie aufgebaut. Sowohl alle ProKI-Standorte als auch einige ProLern-Projekte haben dabei einen Fokus auf dem Menschen und untersuchen das soziale Umfeld und die Interaktion zwischen Mensch und KI. Die technischen Herausforderungen sind so variantenreich wie die Produktionstechnik selbst, sodass in den Projekten von der Erschließung neuer Automationspotenziale, über die Produktivitätssteigerung beim Fügen bis zur Abschätzung der Reststandzeit von Werkzeugen viele Lösungen entwickelt werden.

Aufgrund des breiten Kompetenzprofils wurden die Koordinatoren des ProKI-Netzes mit der redaktionellen Leitung des vorliegenden Atlas betraut. Dieser beinhaltet einerseits einen Leitfaden für die Einführung von KI in Unternehmen und andererseits Best Practices, die in zahlreichen Artikeln wissenschaftlich belastbare Erkenntnisse aus den vergangenen Jahren vermitteln. Unser Dank gilt den vielen Unterstützerinnen und Unterstützern, die die Inhalte für den Atlas aufbereitet und zur Verfügung gestellt haben. Weiterhin danken wir dem Projektträger Karlsruhe und dem Referat KI des Bundesministeriums für Bildung und Forschung für das Vertrauen. Ein weiterer Dank geht an die Agentur wesentlich. und namentlich an Saskia Petermann für die wunderbare Gestaltung dieses Projektatlas.



PROJEKTE WIE PROKI UND PROLERN ZEIGEN, WIE WICHTIG ES IST, DASS EXPERTEN AUS VIELEN BEREICHEN ZUSAMMEN ARBEITEN.



ChatGPT

An dieser Stelle möchten wir die Projekte vorstellen, auf deren Grundlage der Projektatlas entstanden ist. Und wer wäre besser geeignet, über KI-Projekte zu schreiben als eine KI? Natürlich mussten wir etwas nachhelfen und das verwendete Sprachmodell an der ein oder anderen Stelle mit den richtigen Informationen füttern. Aber machen Sie sich am besten selbst ein Bild von unserem Zwiegespräch mit ChatGPT.

Hallo ChatGPT, ich habe von den Projekten ProKI und ProLern gehört. Könntest du mir mehr darüber erzählen?

ChatBox

Natürlich, das mache ich gerne! ProKI und ProLern sind zwei spannende Initiativen, die sich mit der Einführung und Anwendung von Künstlicher Intelligenz (KI) in der Produktion beschäftigen. Möchtest du zuerst über ProKI oder ProLern sprechen?

Lass uns mit ProKI anfangen. Was genau ist das Ziel dieses Projekts?

ChatBox

ProKI oder das „Demonstrations- und Transfernetzwerk KI in der Produktion“ hat das Ziel, Unternehmen – insbesondere kleine und mittlere Unternehmen (KMU) – bei der Einführung von KI in ihren Produktionsprozessen zu unterstützen. Das Projekt baut ein deutschlandweites Netzwerk auf, das den Transfer von KI-Know-how aus den Hochschulen in die betriebliche Praxis beschleunigen soll. Es geht darum, das Potenzial von KI in der Produktion sichtbar zu machen und Unternehmen dabei zu helfen, KI-Lösungen eigenständig in ihrem realen Produktionsumfeld zu etablieren. Besonders adressiert werden dabei die Fertigungsverfahren Fügen, Trennen, Umformen und Beschichten.

Das klingt interessant. Welche Standorte sind in ProKI involviert?

ChatBox

ProKI ist tatsächlich an mehreren Standorten in Deutschland aktiv. Zu den beteiligten Städten gehören Aachen, Berlin, Darmstadt, Dresden, Hannover, Ilmenau, Karlsruhe und Nürnberg. An diesen Standorten werden verschiedene Demonstratoren entwickelt, die KMU die Möglichkeiten von KI in der Produktion aufzeigen sollen.



Wie wird das Projekt denn konkret durchgeführt?

ChatBox

Durchgeführt wird das Projekt auf zweierlei Weisen. Einerseits werden Demonstratoren entwickelt, die den Unternehmen zeigen, wie KI in unterschiedlichen Fertigungsverfahren wie Fügen, Trennen, Umformen und Beschichten eingesetzt werden kann. Andererseits wird darauf geachtet, dass der Einsatz von KI auch humanzentriert erfolgt. Hierbei kommen innovative Methoden und partizipative Forschungsworkshops zum Einsatz.

Und wer fördert das Ganze?

ChatBox

Das Projekt wird vom Bundesministerium für Bildung und Forschung (BMBF) im Rahmen der Fördermaßnahme „Demonstrations- und Transfernetzwerk KI in der Produktion (ProKI-Netz)“ gefördert. Der Projektträger ist PTKA, der Projektträger Karlsruhe, der das Projekt administrativ unterstützt.

Jetzt interessiert mich ProLern. Was steckt dahinter?

ChatBox

ProLern ist ein weiteres spannendes Projekt, das im Rahmen der Ausschreibung „Zukunft der Wertschöpfung“ entstanden ist. Es konzentriert sich auf die „Lernende Produktionstechnik“, also den Einsatz von KI in der Produktion. Ziel ist es, KI-Technologien so zu gestalten, dass sie kontinuierlich lernen und sich an neue Bedingungen anpassen können, um die Produktion effizienter zu gestalten.

Gibt es ein Beispielprojekt aus ProLern?

ChatBox

Ja, eines der Projekte aus ProLern befasst sich mit der „Generalisierung menschenzentrierter KI-Anwendungen“. Hierbei geht es darum, KI-Anwendungen zu entwickeln, die menschenzentriert und anpassungsfähig sind, um die Interaktion zwischen Mensch und Maschine in der Produktion zu verbessern.

Ich habe gehört, dass an einem Projektatlas gearbeitet wird. Was wären da geeignete Inhalte?

ChatBox

Der Projektatlas sollte als Leitfaden dienen und praxisnahe KI-Lösungen vorstellen, die in den Projekten entwickelt wurden. Er könnte Unternehmen und Forschungseinrichtungen als Ressource zur Verfügung stehen, um die Integration von KI in der Produktion zu unterstützen und weiter voranzutreiben. Der Atlas würde vermutlich sowohl praktische Anwendungsbeispiele als auch theoretische Hintergründe zu den entwickelten Technologien enthalten.

Das klingt alles sehr technisch und ambitioniert. Aber GPT, bist du sicher, dass du alles korrekt wiedergegeben hast?

ChatBox

Ich gebe mein Bestes, dir präzise Informationen zu liefern, aber ich bin nicht unfehlbar. Es kann vorkommen, dass ich einige Details nicht ganz korrekt wiedergebe oder etwas übersehe. Es ist immer eine gute Idee, die Informationen zu überprüfen oder zusätzliche Quellen hinzuzuziehen, um sicherzugehen.

Danke für die Ehrlichkeit. Gibt es bestimmte Herausforderungen, die bei der Umsetzung solcher Projekte besonders häufig auftreten?

ChatBox

Absolut! Sowohl die Entwicklung von KI-Technologien als auch ihre Anwendung in der Produktion sind komplexe Aufgaben, die Fachwissen aus verschiedenen Disziplinen erfordern. Projekte wie ProKI und ProLern zeigen, wie wichtig es ist, dass Experten aus unterschiedlichen Bereichen zusammenarbeiten, um innovative und zuverlässige Lösungen zu entwickeln. Der erwähnte Projektatlas ist ein weiteres Beispiel dafür, wie die Erkenntnisse und Entwicklungen aus diesen Projekten praxisnah aufbereitet und zur Verfügung gestellt werden.

*Verwendet Algorithmen
OpenAI. (2023). ChatGPT (Version GPT-4o, 23. August) [Large language model (LLM)]. <https://chat.openai.com/chat>.*

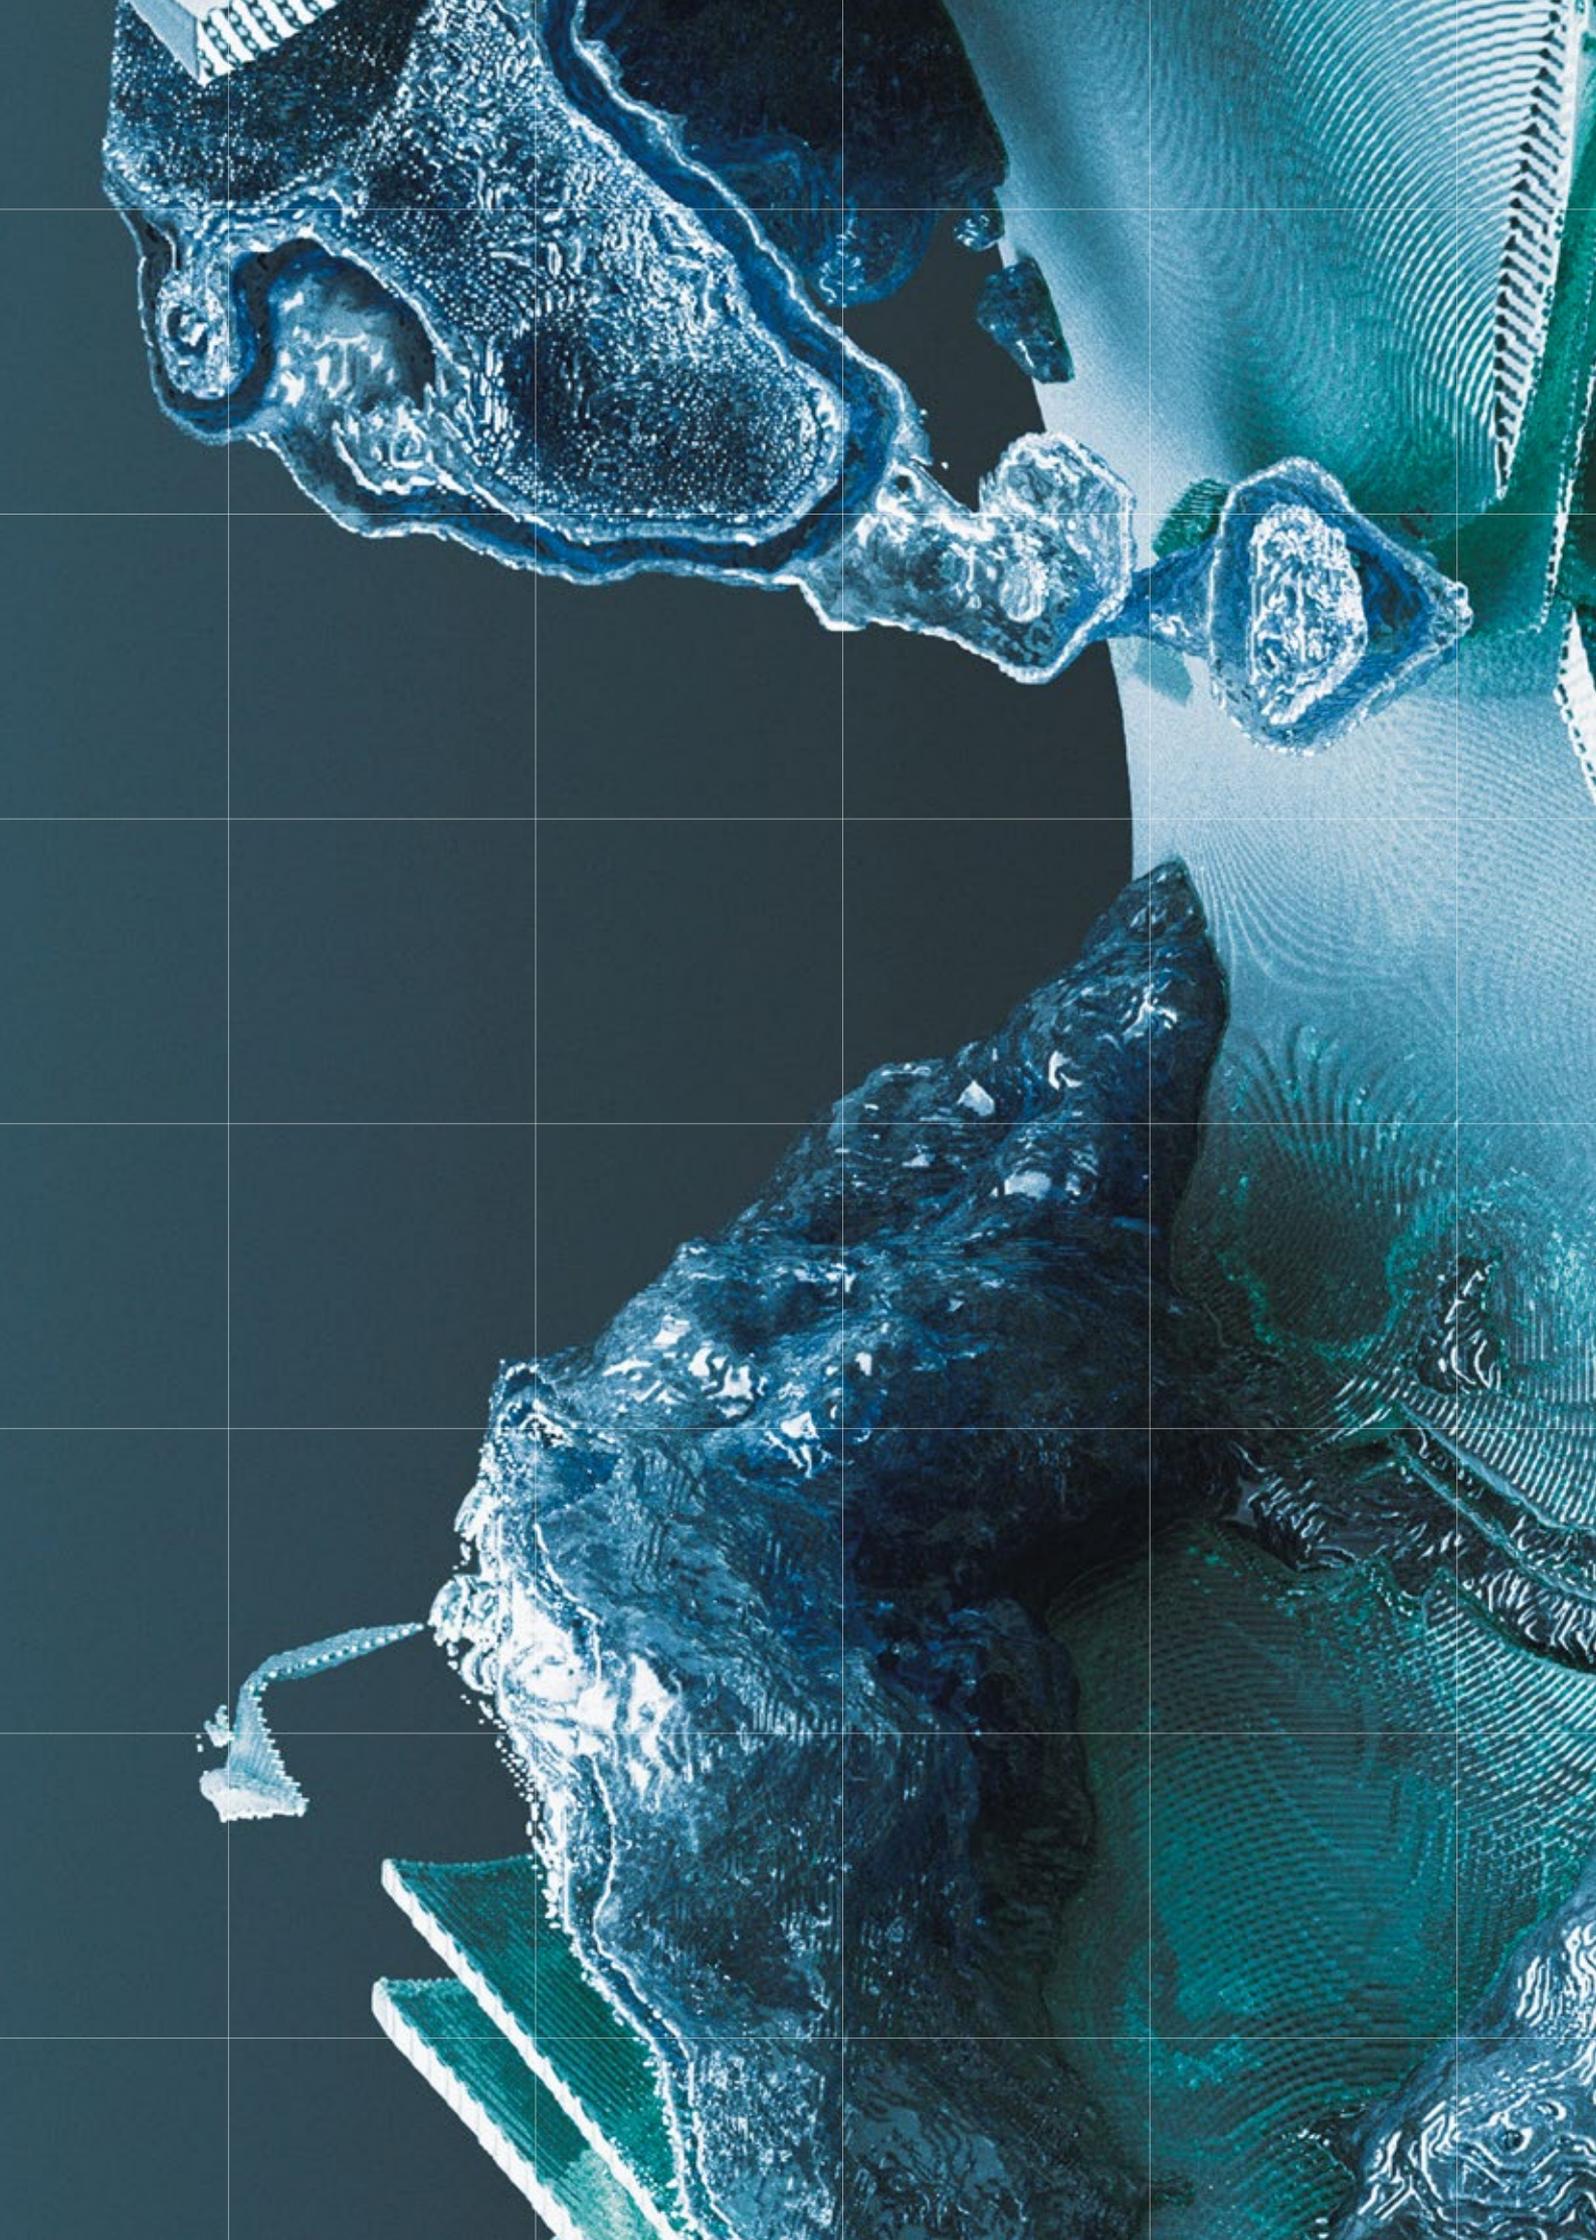
LEITFADEN ZUR EINFÜHRUNG VON KI

Dieser Leitfaden soll als Unterstützung dienen, wenn Sie planen, erste KI-Lösungen zu erarbeiten oder das Fundament für eine erfolgreiche Umsetzung durch die Datenerfassung und -bewertung sowie die Digitalisierung der Fertigung zu legen.

Er zeigt auf, welche Dinge zu beachten sind, welche Herausforderungen zu lösen sind und welche Lösungsstrategien anzuwenden sind.

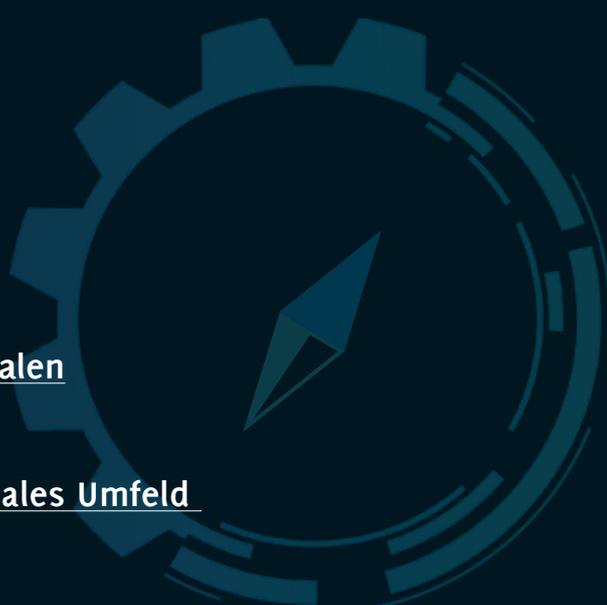
Neben den technischen Fragestellungen sind auch die organisatorischen Aspekte wichtig, wenn die Umsetzung eines KI-Projekts gelingen soll. Natürlich benötigt jedes Unternehmen individuelle Lösungen. Doch dieser Leitfaden kann Ihnen die ersten Schritte auf dem Weg zum Einsatz von KI erleichtern.

Natürlich können Sie diesen Leitfaden ebenso nutzen, um den aktuellen Stand des Unternehmens besser einzuschätzen, die richtigen Fragen zu stellen und häufige Fehler zu vermeiden. Die Mitarbeitenden des Unternehmens nicht nur abzuholen, sondern von Beginn an mitzunehmen. Die Kapitel orientieren sich zwar in etwa an einer möglichen Reihenfolge des Vorgehens, sind aber alle für sich allein stehend nutzbar.



DIE IDENTIFIKATION VON ANWENDUNGSFÄLLEN FÜR KI-LÖSUNGEN KANN SOWOHL PROZESSORIENTIERT ALS AUCH DATENGETRIEBEN ERFOLGEN. BEIDE VORGEHENSWEISEN BENÖTIGEN JEDOCH EINE VORHERGEHENDE ANALYSE.



- 
- 16** Identifikation von Potentialen für KI-Anwendungen
 - 19** Soziales und organisationales Umfeld von KI-Anwendungen
 - 24** Einordnung, Erfassung und Bewertung von Daten für KI-Anwendungen
 - 34** Bewertung und Nutzung der KI-Anwendungen im Arbeitsumfeld
 - 39** Planung der Einführung von KI-Anwendungen



IDENTIFIKATION VON POTENZIALEN FÜR KI-ANWENDUNGEN

Lukas Gründel, Calvin Kuhn, Josefine Monnet, Hanwen Zhang und Eike Reuter (Werkzeugmaschinenlabor WZL der RWTH Aachen)

Managerial Summary:

Die Identifikation von Anwendungsfällen für KI-Lösungen kann sowohl prozessorientiert als auch datengetrieben erfolgen. Beide Vorgehensweisen benötigen jedoch eine vorhergehende Analyse, um einen zielgerichteten Einsatz von KI zu gewährleisten. Initial ist es notwendig, übergeordnete Ziele klar zu definieren. Dabei können Erfahrungen aus der Forschung oder von marktbegleitenden Unternehmen eine wertvolle Hilfestellung bieten. Aufbauend auf der Zielsetzung und Problemidentifikation ist es möglich in mehreren Stufen den ökonomischen, ökologischen und sozialen Nutzen einer potenziellen KI-Lösung zu bewerten. Dies umfasst ein tiefgehendes Verständnis des Problems, die Überprüfung der Datenverfügbarkeit, Definition von Erfolgskriterien, die Abschätzung der technischen Machbarkeit, eine Kosten-Nutzen-Analyse, die Betrachtung rechtlicher und ethischer Aspekte, Change-Management sowie Risiko-Bewertung und auch die perspektivische Testphase und Evaluierung. Darauf aufbauend kann in Kombination mit den vorhandenen technischen Rahmenbedingungen die Auswahl eines Anwendungsfalls für eine KI-Lösung getroffen werden.

Das vorherige Kapitel hat die grundlegende Motivation hinter dem Einsatz von Algorithmen der Künstlichen Intelligenz (KI) für produktionstechnische Anwendungsfelder deutlich gemacht. Durch die Steigerung der Prozesseffizienz, die Einsparung von Ressourcen oder

die Entlastung von Mitarbeitenden von monotonen Arbeitsschritten werden sowohl ökonomische als auch ökologische und soziale Faktoren im Unternehmen verbessert. Der erste Schritt zur Implementierung einer KI-Applikation ist die Identifikation eines geeigneten Anwendungsfalls.

Grundsätzlich bestehen zwei Herangehensweise zur Identifikation - den prozessorientierten „Pull“- oder den datengetriebenen „Push“-Ansatz. Dem prozessorientierten „Pull“-Ansatz liegt ein konkreter Bedarf der Prozessoptimierung zugrunde, auf Basis dessen die Daten erfasst und aufbereitet werden. Um hier Potenziale zu identifizieren, ist es erforderlich, die verschiedenen Phasen des Prozesses detailliert zu betrachten, um beispielsweise potenzielle Schwachstellen, ineffiziente Teilschritte oder repetitive Tätigkeiten zu identifizieren. Dabei gilt es, die Stärke von KI-Algorithmen, Muster in komplexen Prozessen zu erkennen, sinnvoll einzusetzen. Im Unterschied dazu wird beim zweiten Ansatz „Push“ auf Grundlage der bereits verfügbaren Datenbasis eine Möglichkeit gesucht, aus dieser mithilfe von KI-Algorithmen Mehrwert zu generieren. Die zunehmende Vernetzung von Maschinen und Anlagen im Kontext von Industrie 4.0 schafft eine breite und umfassende Basis an Prozessdaten. Sowohl für den „Pull“- als auch für den „Push“-Ansatz ist es in der Vorbereitung auf die Implementierung von KI der erste Schritt, zunächst die bestehenden Herausforderungen und Probleme in der Produktion



zu analysieren. Dieser Schritt ist von entscheidender Bedeutung, um sicherzustellen, dass die Integration von KI-Technologien zielgerichtet erfolgt.

Fortschritte in Forschung und Entwicklung

Bevor mit der Use Case Identifikation für die Anwendung von KI in der Produktion begonnen wird, ist es wichtig, ein klares Verständnis Ihrer übergeordneten Ziele zu haben. Zunächst ist es wichtig, die Frage zu klären, welches Ziel erreicht werden soll. Anschließend sollte eine sorgfältige Literaturrecherche durchgeführt werden, bei der die Suchstrategie definiert wird: Was sind Ihre Suchbegriffe? Auf welche Ressourcen haben Sie Zugriff? Wie soll der Suchprozess gestaltet werden? Nachdem Sie für die Festlegung der Suchstrategie diese Fragen beantwortet haben, sollten die ausgewählten Literaturquellen hinsichtlich ihrer Qualität bewertet werden. Hier können Sie sich beispielsweise an folgenden Fragen orientieren: Sind die Forschungsziele klar formuliert? Ist die vorgeschlagene Methode deutlich beschrieben? Ist die Vorgehensweise angemessen? Wird das Experiment mit ausreichenden Projektdatensätzen oder Fallstudien durchgeführt? Falls die ausgewählten Literaturquellen eine ausreichende Qualität aufweisen, müssen zum Abschluss der Problemidentifikation folgenden Fragen beantwortet werden: Trägt die Forschung einen Mehrwert zum Erreichen Ihres übergeordneten Zieles bei? Ist das Forschungsergebnis übertragbar auf Ihre Anwendungsfälle?

Use Case Identifikation und allgemeines Vorgehen

Alternativ kann die Use Case Identifikation anhand einer Analyse der Wettbewerber durchgeführt werden. Durch den Vergleich der Wettbewerber mit dem eigenen Unternehmen können die Stärken und Schwächen des Unternehmens identifiziert werden. Bei der Wettbewerberanalyse sollen folgende Fragen beantwortet werden: Wer sind die Wettbewerber in relevanten Themen- bzw. Technikbereichen? Wie stark ist die eigene Technologieposition in diesen Bereichen im Vergleich

zu den relevanten Wettbewerbern (quantitativ und qualitativ)? Welche Technologien können bereits jetzt als relevant erkannt werden? Sind diese Technologien auf Ihre Anwendungsfälle übertragbar? Welches Entwicklungspotenzial haben diese Technologien? Nachdem die Use Cases identifiziert worden sind, haben, soll die Eignung von KI-Algorithmen zur Lösung dieser Probleme bewertet werden. Dazu sind sowohl die technische Umsetzbarkeit inklusive der erforderlichen Randbedingungen zu prüfen als auch der Implementierungsaufwand und der ökonomische/ökologische/soziale Nutzen abzuwägen. Dies kann anhand der folgenden zehn Punkte erfolgen:

1. Verständnis der Problemstellung: Zunächst ist es entscheidend, die Problemstellung in ihrer Tiefe zu verstehen. Welche Herausforderung soll gelöst werden? Welche Daten sind verfügbar? Welche Ergebnisse werden angestrebt? Je besser die Problemstellung verstanden ist, desto gezielter kann der Einsatz von KI evaluiert werden.

2. Datenverfügbarkeit: KI-Modelle sind datengetrieben. Es muss geprüft werden, ob ausreichende Daten vorhanden sind, um ein KI-Modell zu trainieren. Die Qualität, Vollständigkeit und Aktualität der Daten sind ebenfalls von großer Bedeutung. Das wird im Kapitel „Einordnung, Erfassung und Bewertung von Daten für KI-Anwendungen“ genauer aufgezeigt.

3. Zielsetzungen und Erfolgskriterien: Die Ziele, die mit dem Einsatz von KI erreicht werden sollen, müssen geklärt sein. Es müssen Erfolgskriterien definiert werden, die es ermöglichen, den Erfolg oder Misserfolg des Projekts zu messen.

4. Technische Machbarkeit: Die technische Machbarkeit muss gegeben sein. Welche Art von KI-Modellen ist erforderlich (z. B. neuronale Netze, Support Vector Machines, kNN)? Sind die erforderlichen Ressourcen vorhanden, um diese Techniken umzusetzen?

5. Kosten-Nutzen-Analyse: Die Kosten für die Entwicklung und Implementierung eines KI-Systems müssen vorab abgeschätzt werden. Kosten und Nutzen



sind dabei gegenüberzustellen, langfristige Kosten, wie für Wartung und erneutes Trainieren von Modellen müssen ebenfalls mit einbezogen werden.

6. Rechtliche und ethische Aspekte: Es muss geprüft werden, ob der Einsatz von KI mit rechtlichen Vorschriften und ethischen Standards in Einklang steht. Datenschutz, Transparenz und Fairness sind hierbei wichtige Faktoren.

7. Change-Management: Wie sich der Einsatz von KI auf die bestehenden Arbeitsprozesse und die Mitarbeitenden auswirkt, ist ebenfalls zu berücksichtigen. Das umfasst unter anderem die Planung von Schulungen und Maßnahmen im Change-Management. Auch die Akzeptanz der Mitarbeitenden ist erforderlich.

8. Risikobewertung: Potenzielle Risiken und Unsicherheiten im Zusammenhang mit dem Einsatz von KI müssen identifiziert und Strategien zur Risikominimierung entwickelt werden.

9. Prototyping und Testphasen: Vor der vollständigen Implementierung ist es ratsam, Prototypen und Testphasen durchzuführen, um die Machbarkeit und Leistung des KI-Systems zu validieren.

10. Kontinuierliche Evaluierung: KI-Systeme sind nicht statisch. Es sollte regelmäßig überprüft werden, ob das System die gesteckten Ziele erreicht und gegebenenfalls Anpassungen vornehmen. KI-Modelle können basierend auf historischen Daten Vorhersagen treffen, allerdings können unvorhergesehene Ereignisse und externe Einflüsse das reale Verhalten darüber hinaus beeinflussen. Streng betrachtet, ist die Evaluierung nicht der Potenzialanalyse im Vorfeld des Einsatzes von KI zuzuordnen. Es muss jedoch vorab abgesichert werden, dass eine Evaluierung der KI-Modelle realisierbar ist.

Je nach Anwendungsfall bringt die Implementierung von KI-Algorithmen unterschiedlich große Herausforderungen mit sich. Neben der technischen Machbarkeit sind zudem sowohl strukturell-organisatorische als auch ethische Aspekte zu berücksichtigen. Im

Folgenden werden technische Randbedingungen und Grenzen sowie potenzielle Maßnahmen bei der Auswahl geeigneter Anwendungsfälle für KI aufgeführt. Die bereits genannte Vernetzung von Maschinen und Anlagen ist besonders im Hinblick auf eine Brown-field-Umgebung nicht ohne Probleme umzusetzen. Vorhandene Maschinen- und Anlagensteuerungen verwenden unterschiedliche, mitunter proprietäre Protokolle und verfügen nicht über die erforderlichen Schnittstellen, um eine nahtlose Anbindung an eine Edge- oder Cloudlösung zu ermöglichen. Sollten erforderliche Sensordaten nicht oder nicht im gewünschten Format erfasst werden, so ist eine Nachrüstung mit externer Sensorik erforderlich. Werden die KI-Algorithmen in bestehende Prozesse integriert, ist deren Kompatibilität mit vorhandenen Steuerungsalgorithmen zu gewährleisten, sodass originäre Steuerungsaufgaben uneingeschränkt funktionieren und keine Stillstände verursachen. Im selben Zug ist auch die Restunsicherheit zu nennen, die durch die Verwendung von KI-Algorithmen stets in den Prozess eingebracht wird. Systeme, die auf Basis dieser Entscheidungen treffen, sind mitunter intransparente Black-Box-Modelle. Welche Zusammenhänge der Algorithmus genau lernt, auf deren Basis er Entscheidungen trifft, ist nur eingeschränkt nachvollziehbar. Die Erzielung einer Genauigkeit von 100 % ist praktisch ausgeschlossen. Eine Restunsicherheit bleibt stets erhalten. Eine Genauigkeit von 100 % ist jedoch auch bei konventionellen Messsystemen nicht zu realisieren. Die Zuverlässigkeit trainierter KI-Modelle sollte daher eingehend geprüft und mit den Anforderungen abgeglichen werden. Dabei sind sowohl wirtschaftliche Risiken als auch Gefahren, die sich für in der Umgebung befindende Menschen ergeben, zu berücksichtigen. Die ordnungsgemäße Funktionsweise von KI-Algorithmen, insbesondere bei Anpassungen im Prozess, muss regelmäßig überprüft werden. Wie im folgenden Kapitel deutlich werden wird, muss bei der Implementierung von KI-Algorithmen in produktionstechnischen Umgebungen stets das soziale Umfeld inklusive aller beteiligten Stakeholder betrachtet werden.



SOZIALES UND ORGANISATIONALES UMFELD VON KI-ANWENDUNGEN

Verena Nitsch, Laura Johnen, (Lehrstuhl und Institut für Arbeitswissenschaft IAW der RWTH Aachen), Sabine Pfeiffer, Bruno Albert, Silke Röbenack und Romy Blinzler (Lehrstuhl für Soziologie mit dem Schwerpunkt Technik – Arbeit – Gesellschaft am Institut für Soziologie an der Friedrich-Alexander-Universität Erlangen-Nürnberg)

In den letzten Jahren ist das Interesse und die Erwartung an Technologien Künstlicher Intelligenz (KI) in der Produktion und in den produktionsunterstützenden Bereichen wie Qualitätsmanagement oder Instandhaltung deutlich gestiegen. Die tatsächliche Nutzung entspricht allerdings weder der medialen Aufmerksamkeit noch den Erwartungen. Insbesondere kleinere und mittlere Unternehmen (KMU) sind gegenüber den neuen KI-Technologien zurückhaltend.^[12] Zwar können KI-Lösungen auch für KMU Effizienzzuwachs sowie neue Produkte bzw. Leistungen ermöglichen,^[13, 14] jedoch ist deren Einsatz nach wie vor voraussetzungsreich.^[12] Die Zurückhaltung ist angesichts der für die Integration der KI-Technologien notwendigen finanziellen, organisatorischen und personellen Ressourcen und Kompetenzen rational begründet und nachvollziehbar.^[12, 15, 16]

Aus diesem Grund ist es für interessierte Unternehmen in einer ersten Analysephase angebracht, sich zunächst die Frage zu stellen, ob und inwiefern ein KI-Einsatz für die Produktions- bzw. Leistungsstrukturen funktional (effektiv) und zugleich wirtschaftlich

sinnvoll (effizient) ist: Wie kann das Unternehmen im Hinblick auf existierende externe und interne Rahmenbedingungen von einer KI-Einführung profitieren? Wird diese Frage positiv beantwortet, sollten die Unternehmensführungen in einem zweiten Schritt und noch vor einem möglichen Einführungsprozess prüfen, ob und inwiefern Unternehmensstrukturen angepasst werden müssen und ob die Kapazitäten hierfür vorhanden sind. Ähnlich zu anderen technisch-organisatorischen Change-Prozessen empfiehlt es sich, frühzeitig systematisch die direkten Auswirkungen und auch die indirekten Folgewirkungen auf die Beschäftigten zu analysieren und insbesondere auch die Erwartungen bzw. Befürchtungen sowie Potenziale gemeinsam mit den Beschäftigten^[17, 18] und gegebenenfalls auch mit Kund*innen zu eruieren.^[13]

Im Folgenden werden⁽¹⁾ die zentrale Bedeutung der Beteiligung der Beschäftigten bei der Arbeitsgestaltung und⁽²⁾ die notwendige Berücksichtigung der Organisation als jeweils spezifische soziotechnische Einheit für eine nachhaltige Implementation von KI-Lösungen diskutiert.



Partizipation in der Arbeitsgestaltung als Voraussetzung für eine nachhaltige Einführung von KI

Verena Nitsch und Laura Johnen

Managerial Summary:

- Die Beteiligung von Beschäftigten an betrieblichen Veränderungs- und Entscheidungsprozessen (Partizipation) ist der Schlüssel zur erfolgreichen Einführung von neuen Technologien.
- Eine menschenzentrierte Gestaltung von Innovationen in frühen Phasen des Entwicklungsprozesses hilft, hohe Kosten durch spätere Anpassungen zu vermeiden.
- Wichtige Stakeholder sind Anwendende, direkt und indirekt Betroffene. Zu berücksichtigen sind zudem Dimensionen wie Umwelt oder Recht (bspw. Umweltschutz und Datenschutz).
- In Workshops können verschiedene Perspektiven aller Stakeholder gebündelt und Umsetzungsalternativen analysiert und verglichen werden.

Die Integration von KI in betriebliche Abläufe und Arbeitsumgebungen hat zweifellos das Potenzial, Unternehmen in hohem Maße zu transformieren und ihre Wettbewerbsfähigkeit zu steigern: In der Produktion ermöglicht der Einsatz von KI deutliche Qualitätsverbesserungen durch Prozessoptimierung,^[19] die Erschließung neuer Geschäftsmodelle und -praktiken^[20] sowie eine Effizienzsteigerung durch Echtzeitentscheidungsunterstützung [21]. Die Einführung von KI soll einerseits dazu beitragen, Abläufe effizienter zu gestalten, andererseits auch Mitarbeitende entlasten, indem repetitive Aufgaben automatisiert werden. Allerdings ist es von entscheidender Bedeutung, zu verstehen, dass der erfolgreiche Einsatz von KI weit über die bloße Implementierung von Technologie hinausgeht, sondern stattdessen als Teil eines komplexen soziotechnischen Arbeitssystems verstanden werden muss: Mit der Implementierung von KI geht oft

eine Verschiebung von Aufgabeninhalten und -schwerpunkten einher, begleitet von neuen Anforderungen und Zuständigkeiten.^[22] Eine zentrale Säule, die in diesem Prozess nicht vernachlässigt werden darf, ist die Partizipation.

Partizipation, also die Beteiligung von Beschäftigten an betrieblichen Veränderungs- und Entscheidungsprozessen, wird oft als Schlüssel zur erfolgreichen Einführung von neuen Technologien beschrieben.^[23] Mitarbeitende in Entscheidungsprozesse und Implementierungsstrategien einzubeziehen, bietet mehrere Vorteile: Zunächst ermöglicht die Einbeziehung der Mitarbeitenden in die Entscheidungsfindung und Implementierung von KI-Technologien eine erhöhte Akzeptanz (vgl. Kapitel) und Identifikation mit den neuen Lösungen. Mitarbeitende, die an diesem Prozess beteiligt sind, sind eher bereit, die notwendigen Veränderungen zu unterstützen und mitzutragen.^[24] Die Einbeziehung der Mitarbeitenden erlaubt die Berücksichtigung verschiedener Perspektiven. Dadurch kann sowohl potenzieller Verzerrung (Bias) und Diskriminierung vorgebeugt als auch ein Gefühl der Eigenverantwortung und Verbindung zum Wandel geschaffen werden.

Gleichzeitig setzt eine erfolgreiche Partizipation zeitliche und personelle Ressourcen sowie die erforderliche Fachexpertise für den partizipativen Prozess voraus, da sonst nachteilige Effekte auftreten können, wie etwa eine Verlangsamung von Entscheidungsprozessen bei Erhöhung der Arbeitsverdichtung und der damit verbundene Stress für die involvierten Beschäftigten. Eine grundlegende Herausforderung bei der Einführung von neuen Technologien besteht in der schon angesprochenen Veränderung von Arbeitsinhalten und -schwerpunkten. Neue Arbeitsbedingungen sollten immer hinsichtlich kognitiver und physischer Auswirkungen auf die Arbeitspersonen sowie sozialer Effekte bewertet werden. Anderenfalls besteht das Risiko, dass suboptimale Gestaltungslösungen umgesetzt werden, die weder aus betriebswirtschaftlicher



noch aus gesundheitlicher Perspektive zielführend sind. Eine menschenzentrierte Gestaltung von Innovationen ist daher bereits in frühen Phasen des Entwicklungsprozesses wichtig.

Folglich sollte bei Entwicklung und Einführung einer neuen Technologie neben der Innovation selbst (z. B. Funktionalität, Zuverlässigkeit und Sicherheit) auch die Interaktion zwischen Innovation und Stakeholdern berücksichtigt werden, um unerwünschte Auswirkungen zu vermeiden.^[25] Werden unerwünschte Effekte erst am Ende des Forschungs- und Entwicklungsprozesses einer Innovation deutlich, führt das zu hohen Kosten und möglicherweise zur Schädigung der Reputation.^[26]

Als Beispiele für unerwünschte Effekte bei der Einführung von KI in die Produktion geben Brandl et al. die Verletzung des Datenschutzes aufgrund zu weitreichender Datenerhebung und -speicherung oder die Demotivation der Mitarbeitenden aufgrund fehlender Einbeziehung in nun vollständig automatisierte Entscheidungsprozesse an^[26]. Wichtig, um die nachhaltige Einführung von KI in Unternehmen zu gewährleisten, ist daher die frühzeitige Einbindung von Stakeholdern. Um hohe Kosten durch späte Anpassungen zu vermeiden, sollte dies begleitend zum Entwicklungsprozess geschehen. Auf diese Weise können, beispielsweise in Form von Workshops, verschiedene Umsetzungsalternativen analysiert und verglichen werden. Wichtige Stakeholder sind dabei die folgenden Gruppen: Anwendende der Technologie, direkt und indirekt Betroffene, auch Dimensionen wie Umwelt oder Recht (bspw. Umweltschutz und Datenschutz) können tangiert sein. Letztere können von juristischen Personen oder Interessengruppen vertreten werden. Die Auswahl der Stakeholder sollte insgesamt das Ziel verfolgen, verschiedene Perspektiven zu integrieren. Stakeholder, die in ähnlicher Weise von der geplanten Innovation betroffen sind, können daher zusammengefasst werden. Der aufgeführte Prozess kann mit Risikoanalysen wie beispielsweise mit der AMICAI-Methode begleitet werden, die detailliert in^[15] dargestellt ist.

KI und Organisation

Sabine Pfeiffer, Bruno Albert, Silke Röbenack und Romy Blinzler

Managerial Summary:

- Organisationale Prozesse müssen bei der Implementierung und beim Betrieb von KI-Anwendungen systematisch mitgedacht werden.
- Ziel sollte es dabei sein, das Unternehmen handlungs- und reaktionsfähig zu halten, auch in Bezug auf sich verändernde Rahmenbedingungen des KI-Einsatzes.
- Dabei muss vor allem geregelt werden, bei wem beim Einsatz von KI die Entscheidungsmacht liegt.
- Zu diesem Zweck müssen Beschäftigte befähigt werden, KI-Anwendungen zu verstehen und den entstehenden Output zu bewerten.

Neben technischen und sozialen Aspekten muss bei der Einführung von KI auch beachtet werden, dass sowohl der Einsatz der Technologie als auch die Entscheidungen, die in diesem Zusammenspiel von Menschen und Technologie getroffen werden, in die jeweiligen spezifischen organisationalen Zusammenhänge eingebettet sind. Diese Zusammenhänge folgen oft einer Eigenrationalität und sind wiederum Teil komplexer externer Umgebungen.

Das lässt sich am Beispiel der vorausschauenden Instandhaltung (engl. predictive maintenance) illustrieren. Die vorausschauende Instandhaltung gilt derzeit als eine der wichtigsten KI-Anwendungen für die Industrie 4.0.^[27] Wartung und Instandhaltung sind seit je Gegenstand von Voraussicht und Planung. Bei Großanlagen, zum Beispiel in der chemischen Produktion oder in der Energie- sowie Abwasserinfrastruktur, geht es jedoch darum, die Intervalle und die Dauer von Stillständen zu minimieren, unerwartete Störungen möglichst zu vermeiden und Ersatzteile so oft wie nötig, aber so spät und so selten wie möglich zu beschaffen oder zu ersetzen. Es ist technisch möglich geworden, nicht nur die große Menge an Daten, die



in den eingebetteten Systemen der Anlagen erzeugt werden, in Echtzeit auszuwerten, sondern auch über lange Zeiträume erzeugte Datensätze auf bisher unentdeckte Zusammenhänge zu untersuchen und so den Ausfall von bestimmten Teilen einer Produktionsanlage statistisch vorherzusagen. Dadurch können diese Teile gewechselt werden, bevor es zu einem Ausfall des Teils und dadurch zu einem kostenintensiven Stillstand kommt.

Bei der Einführung von KI-Anwendungen wie bei der vorausschauenden Instandhaltung wird der Fokus zunächst oft vordergründig auf technische Fragen der Implementierung gelegt. In dem Moment, in dem eine solche Anwendung jedoch eine Meldung ausgibt, entstehen eine Reihe organisatorischer Fragen, die im Unternehmen durch Prozesse geregelt werden müssen. Zu diesen Fragen gehören unter anderem: Wie ist auf die Meldung zu reagieren? Wer muss informiert werden? Wie kann die Meldung in die routinemäßigen Wartungsaufgaben integriert werden? Wer trägt am Ende die Verantwortung, falls die KI-Meldung fehlerhaft war - das ausführende Wartungspersonal oder die Entwicklungsabteilung, die mit der Einführung der KI betraut war? Wer entscheidet, ob ein teures Spezialteil tatsächlich „auf Verdacht“ getauscht wird? Auf diese und auf viele weitere Fragen, die vom jeweiligen Kontext der KI-Anwendung und des betroffenen Unternehmens abhängen, müssen organisatorische Antworten und Prozesse in verschiedenen Bereichen und auf verschiedenen Ebenen des Unternehmens gefunden und etabliert werden.

Im Folgenden werden einige Handlungsfelder für das Unternehmen in Bezug auf KI skizziert:

Die Entscheidungen, die durch KI getroffen werden, resultieren aus der Verwendung von sich ständig ändernden Daten. Diese Entscheidungen basieren in der Theorie auf rechnerisch nachvollziehbaren, jedoch sehr komplexen Algorithmen und sind daher in der Praxis für die Anwendenden kaum transparent. Die

Auswirkungen des Einsatzes von KI können in der Regel nicht unmittelbar, sondern erst zu einem späteren Zeitpunkt beurteilt werden. Daher ist es auch nach der Implementierung von KI wichtig, die Organisation kontinuierlich über Veränderungen in der KI-Anwendung zu informieren und diese entsprechend einzubinden. In Bezug auf die Mensch-Maschine-Interaktion hat sich in der KI-Forschung das Konzept des „Human-in-the-Loop“ etabliert;^[28] es beschreibt ein Vorgehen, bei dem es eine Rückkopplung zwischen einem Menschen und dem KI-System gibt. Damit ist das Ziel verbunden, dass der Mensch beim Aufbau eines KI-Modells helfen kann, die richtigen Entscheidungen zu treffen, und darüber hinaus gegebenenfalls korrigierend eingreift.^[28] Beim Einsatz von KI gilt dieses Prinzip der Rückkopplung für das gesamte Unternehmen.^[15] Die Unternehmensorganisation muss in der Lage sein, KI-Prozesse zu überwachen und zu regulieren; dafür muss sie die Beschäftigten, die mit der KI-Anwendung arbeiten, mit den notwendigen Kompetenzen ausstatten.

Zu diesem Zweck müssen die Beschäftigten ein grundlegendes Verständnis der Hintergründe für eine KI-Entscheidung und der damit verbundenen Abhängigkeiten entwickeln: Im Falle der vorausschauenden Instandhaltung hieße das beispielsweise, dass die Beschäftigten einschätzen können, unter welchen Bedingungen und mit welcher Wahrscheinlichkeit die Vorhersage der KI-Anwendung zutrifft, dass ein Teil demnächst ausfällt. Dazu sind bestimmte Qualifikationen aufseiten der Beschäftigten erforderlich. Während das Human-Resource-Management häufig für das allgemeine Change-Management verantwortlich ist, findet die konkrete KI-Kompetenz-Entwicklung im Regelfall vor Ort in den operativen Abteilungen statt. Um sicherzustellen, dass die Beschäftigten die notwendigen Qualifikationen für den Einsatz von KI im Unternehmen erhalten, müssen bei der Implementierung von KI die eher technisch orientierten operativen Abteilungen und das Human-Resource-Management eng zusammenarbeiten.



Das Unternehmen muss zudem klare Regeln für den Umgang mit KI-Anwendungen finden. KI-Systeme können fehlerhaft sein und daher unzutreffende Empfehlungen oder Entscheidungen produzieren. Insofern können Beschäftigte gute Gründe haben, der Empfehlung des KI-Systems in bestimmten Situationen nicht zu folgen. Diese menschlichen Entscheidungen können sich jedoch im Nachhinein ebenfalls als unzutreffend erweisen und unter Umständen zu Qualitätsverlusten, hohen Kosten oder sogar haftungsrechtlichen Problemen führen. Wie in solchen Fällen zu verfahren ist und welche Konsequenzen die Mitarbeitenden zu tragen haben, sind Fragen, die die Organisation beantworten bzw. regeln muss.^[29, 30] Diese Regeln hängen vom jeweiligen Kontext ab und müssen im Unternehmen erarbeitet werden. Relevante Kontextfaktoren sind z. B. die Größe des Unternehmens, das hergestellte Produkt oder das Ausmaß der potenziellen Konsequenzen einer KI-Fehlentscheidung. Darüber hinaus muss das Unternehmen sicherstellen, dass diese Regeln sowohl bei den Beschäftigten, die unmittelbar mit KI-Anwendungen befasst sind, als auch bei allen mittelbar von den KI-Entscheidungen Betroffenen (z. B. Einkauf) bekannt sind und akzeptiert werden.

Eine weitere zu klärende Frage ist, ob und wann die KI-Anwendung nachtrainiert werden muss, worauf in Kapitel 8 eingegangen wird. Die Kriterien für solche Entscheidungen müssen ausgehandelt und definiert werden. Grundsätzlich ist das Weiterlernen einer KI-Anwendung sinnvoll, da sich auch der betriebliche Kontext, in dem eine KI-Anwendung eingesetzt wird, permanent wandeln kann. So könnte bei einer KI-Anwendung im Bereich der vorausschauenden Instandhaltung zum Beispiel eine Änderung der Betriebsmittel, wie z. B. der Schmierstoffe, dazu führen, dass sich die Maschine anders verhält und das Modell deshalb an Aussagekraft verliert. Ob und wie ein Weiterlernen stattfindet, muss allerdings unter Berücksichtigung technischer, wirtschaftlicher und/oder haftungsrechtlicher Gründe im Unternehmen entschieden werden.

Für die Reglementierung von KI ist es von großer Bedeutung, die Beschäftigten als Expert*innen ihrer eigenen Arbeit in den Prozess einzubinden, da sie in der Regel über ein breites Erfahrungswissen zu den Prozessen und zum Kontext verfügen, in den die KI-Anwendung eingebettet werden soll^[16]. KI-Implementierungen in Unternehmen sind nicht nur eine Aufgabe für technische KI-Expert*innen, sondern ein komplexer, kontinuierlicher organisatorischer Prozess, in den alle unmittelbar und mittelbar Betroffenen von Anfang an und im weiteren Verlauf einbezogen werden müssen. Wer betroffen ist, unterscheidet sich je nach Unternehmens- und Anwendungskontext. Im Falle der vorausschauenden Instandhaltung ist das Instandhaltungspersonal unmittelbar betroffen; mittelbar betroffen sind unter anderem: produzierende Mitarbeitende an der Maschine aufgrund etwaiger wartungsbedingter Stillstände, der Einkauf, der Ersatzteile zur Wartung beschaffen muss, aber auch die Human-Resources-Abteilungen, die mit der Schulung der betroffenen Mitarbeitenden betraut sind.



EINORDNUNG, ERFASSUNG UND BEWERTUNG VON DATEN FÜR KI-ANWENDUNGEN

Nils Thielen (Friedrich-Alexander-Universität Erlangen-Nürnberg, Lehrstuhl für Fertigungsautomatisierung und Produktionssystematik), Sven Meier (Friedrich-Alexander-Universität Erlangen-Nürnberg, Lehrstuhl für Fertigungsautomatisierung und Produktionssystematik), Varun Pandey (TU Berlin, Fachgebiet Datenbanksysteme und Informationsmanagement), Shahenda Youssef (Karlsruher Institut für Technologie, Lehrstuhl für Interaktive Echtzeitsysteme)

Managerial Summary:

Die Grundlagen für den erfolgreichen Einsatz von Anwendungen Künstlicher Intelligenz bilden die Daten. Dabei ist es nicht ausreichend, historische Daten in großem Umfang aufgenommen zu haben. Es ist essenziell, dass diese für den geplanten Anwendungsfall auch im laufenden Betrieb erfasst werden können. Des Weiteren muss die Datenqualität gewährleistet sein, um die Performance der zu entwickelnden KI-Anwendungen nicht zu reduzieren bzw. gänzlich unbrauchbar zu machen. Dementsprechend adressiert dieses Kapitel die Punkte Datengrundlage, Dateninfrastruktur, Datenqualität sowie die Validierung von Modellen in der Produktion. Letzteres ist ein entscheidendes Kriterium für die Auswahl von Anwendungsfällen sowie der Erweiterung der Datengrundlage. ^[31] Dabei ist es entscheidend, die vorhandenen Daten zu charakterisieren und ihre Qualität zu ermitteln, idealerweise bevor mit der KI-Entwicklung begonnen wird. Ferner muss auch gewährleistet werden, dass die IT-Infrastruktur die Realisierung der KI-Lösung erlaubt.

Einordnung von Daten

Nils Thielen und Sven Meier

Daten können in unterschiedlichen Formen sowie einer Kombination aus diesen Formen vorliegen. Es ist zunächst von Relevanz, diese entsprechend einzuordnen und grundlegend zu charakterisieren. Im Folgenden

werden Leitfragen aufgeführt, an denen sich bei der Charakterisierung von Daten orientiert werden kann. Dabei kann es zu Überschneidungen mit den Schritten des Datenverständnisses in Kapitel „Einführung von KI“ kommen. Anschließend werden die häufigsten Formen von Datensätzen vorgestellt. Auf die Datenverarbeitung selbst wird ebenfalls in Kapitel „Einführung von KI“ sowie in den KI-Lösungen aus der Praxis.

Datensätze charakterisieren:

- Sind bereits Datensätze vorhanden?
- Welche Form haben die vorhandenen Datensätze?
- Wie können die Datensätze aus der Produktion entnommen werden? Gibt es Probleme bezüglich IT- und Datensicherheit?
- Welchen Umfang haben die Datensätze? Müssen zunächst nur Teildatensätze betrachtet werden?
- Wie können die Schnittstellen zu produktionsinternen Softwaresystemen definiert werden?

In Abhängigkeit von der vorliegenden Form gilt es unterschiedliche Kriterien zu überprüfen bzw. die oben aufgeführten Fragestellungen zu spezifizieren. Diese sind für die wichtigsten Datenformen in der Produktion im Folgenden aufgeführt:

Relationale Daten:

- Sind die Daten eindeutig einem Prozess und einem Produkt oder Batch zuzuordnen?



- Handelt es sich bei den Daten um Umgebungsparameter?
- Liegen die Daten bereits in einer relationalen Struktur vor oder müssen sie zusätzlich noch in eine tabellarische Form überführt werden?
- Welche Bedeutung hat ein nicht vorhandener Wert in den betrachteten Datensätzen?
- In welchen Datenformaten liegen die Werte vor (z. B. Integer, Dezimalzahl, String, Zeitstempel)?
- Wie können mehrere relationale Datensätze eindeutig prozess- und produktübergreifend zusammengeführt werden?
- Werden die Daten dauerhaft gespeichert oder nach einer festgelegten Menge überschrieben bzw. nach einem bestimmten Zeitraum gelöscht?

Bilddaten:

- Welches Format haben die Bilddaten (z. B. JPEG, PNG)? Ist dieses standardmäßig zu lesen?
- Enthalten die Bilddaten Artefakte, die durch eine Software hinzugefügt worden sind oder handelt es sich um die unbearbeiteten Aufnahmen?
- Falls Bildartefakte vorhanden sind: Überdecken diese relevante Bereiche des Bildes oder geben sie einen Hinweis auf die potenzielle Bewertung des Bildes?
- Liegen die Bilder in Klassen vor (z. B. gut/schlecht)? Falls ja, wie werden diese Klassen erfasst (z.B. unterschiedlicher Speicherort, zusätzliche Datei)?

- Werden alle Bilddaten abgespeichert oder nur ausgewählte Klassen (z. B. Defekte)?

Zeitreihen:

- Worum handelt es sich bei den betrachteten Zeitreihen (z. B. Prozesskurven)?
- Wie hoch ist der Zeitabstand zwischen den einzelnen Datenpunkten? Wie wird dieser erfasst?
- Falls die Zeitreihe im Rahmen eines Prozesses an der Anlage erfasst wird: Werden die Zeitreihen abgespeichert oder lediglich an der Anlage visualisiert?

Relationale Daten

Relationale Datensätze bestehen aus Datenpunkten, die in einer strukturierten Form vorliegen, üblicherweise in Tabellen. Die korrekte Handhabung und Interpretation von Daten ist von entscheidender Bedeutung. In diesem Kontext verlangt die eindeutige Zuordnung von Werten zu Messgrößen, Seriennummern, Parametern oder weiteren Größen bei tabellarischen Daten besondere Aufmerksamkeit. Zu den gängigen Datentypen zählen String (Textketten), Integer (ganze Zahlen), Float (Gleitkommazahlen), Boolean (Wahrheitswerte), Zeitstempel (Datum und Uhrzeit) und Arrays (Datenfelder). Ebenso wichtig ist die klare Trennung von Eingangs- und Ausgangsparametern. Eingangsparameter dienen als Input für ein System oder einen Algorithmus, während Ausgangsparameter die resultierenden Daten repräsentieren, die aufgrund

Abbildung 1: Beispielhafter Ausschnitt eines tabellarischen Datensatzes mit Primärschlüssel, Attribut (im Kontext mit KI oft Feature bzw. Merkmal) und Label

<i>PRIMÄRSCHLÜSSEL</i>	<i>ATTRIBUT/FEATURE/MERKMAL</i>			<i>LABEL</i>
<i>PRODUKT-ID</i>	<i>PRESSKRAFT</i>	<i>OFENDAUER</i>	<i>OFENTEMPERATUR</i>	<i>QUALITÄTSKONTROLLE/RESULTAT</i>
A234X3454623	50.45	25	172.8	1
A234Z4948284	63.20	20	185.3	1
A234Z4948285	63.83	20	185.4	1
A234X3454624	50.23	25	172.9	0

TUPLE ←



der Verarbeitung des Inputs entstehen. Diese sind oft Stellgrößen, die im Datensatz nur konkrete Werte annehmen. Ein weiteres Unterscheidungsmerkmal, das in vielen Anwendungen von Bedeutung ist, ist die Unterteilung von Soll- und Ist-Parametern. Während Soll-Parameter den gewünschten oder erwarteten Zustand darstellen, beschreiben Ist-Parameter den tatsächlich gemessenen oder beobachteten Zustand und sind häufig einem kontinuierlichen Wertebereich zuzuordnen. Diesen Daten können in unterschiedlichen Formaten wie SQL, .csv und .xml gespeichert werden. Jedes dieser Formate hat seine spezifischen Anwendungsgebiete und Vorteile. Entscheidend ist auch hier die eindeutige Zusammenführung mehrerer Datenquellen.^[32] Ein Beispiel für tabellarische Daten, die aus einer relationalen Datenbank abgeleitet werden können.

Bilddaten

Bilddaten bilden eine weitere relevante Gruppe von Daten bei dem Einsatz von KI. Dabei basieren viele dieser Analysen auf optischen Aufnahmen, wobei es sich nicht zwingend um ein klassisches Kamerabild handeln muss. Unterschiedliche Arten von Aufnahmen, wie Grauwertbilder, Farbbilder, UV-Aufnahmen oder Frames aus Videos, bieten jeweils spezifische Informationen und haben ihre eigenen Anwendungsbereiche und Vorteile. Bei der Verwendung von Bilddaten sind das Format, der Detailgrad und die Dateigröße wichtige Faktoren. Diese beeinflussen sowohl die Qualität der Daten als auch die Anforderungen an die Datenverarbeitung und -speicherung. Insbesondere die Dateigröße von Bilddaten muss bei der Gestaltung der Dateninfrastruktur berücksichtigt werden, da sie einen limitierenden Faktor darstellen kann. Ein weiterer wichtiger Aspekt für Bilddaten ist die Annotation. Dabei werden den Bilddaten zusätzliche Informationen beigefügt, beispielsweise durch das Markieren von bestimmten Merkmalen oder Objekten im Bild. Diese Annotationen sind oft entscheidend, wenn es darum geht, automatisierte Bildanalysesysteme zu trainieren oder die Ergebnisse von solchen Systemen zu validieren. Es gibt vielfältige Anwendungsgebiete

für Bilddaten. Einige Beispiele für Datensätze sind die Qualitätskontrolle, bei der Bilder dazu verwendet werden, Produkte auf Mängel oder Abweichungen zu überprüfen, die Pose Estimation, die die Position und Orientierung von Objekten in den Bildern bestimmt, das Process Monitoring, bei dem Bilddaten dazu genutzt werden, industrielle Prozesse in Echtzeit zu überwachen, und die Predictive Maintenance, bei der Bilder dazu beitragen, den Zustand von Maschinen oder Anlagen zu überwachen und so vorherzusagen, wann Wartungsarbeiten erforderlich sein könnten.^[33]

Zeitreihen

Zeitreihendaten sind eine besondere Art von Daten, die für KI eine wichtige Rolle spielen. In der Produktion können dies beispielsweise Temperatur- und Kraftverläufe sein. Diese Daten bestehen aus einer Reihe von Datenpunkten, die in einer zeitlichen definierten Abfolge angeordnet sind. Jeder Punkt in einer Zeitreihe repräsentiert einen Wert zu einem bestimmten Zeitpunkt, wodurch sich Muster, Trends und Veränderungen über die Zeit hinweg analysieren lassen. In der Praxis können Zeitreihendaten in kontinuierlichen Zeitintervallen erfasst werden, wie beispielsweise stündlich, täglich oder monatlich. Diese regelmäßige Erfassung ermöglicht es, Veränderungen präzise zu verfolgen und Vorhersagen über zukünftige Entwicklungen zu treffen.

Einige der wichtigsten Anwendungen von Zeitreihendaten in der KI sind die Anomalieerkennung und die Trendanalyse. Bei der Anomalieerkennung nutzt man KI, um ungewöhnliche Muster oder Abweichungen in den Daten zu identifizieren. Weiterhin kann eine KI durch die Analyse von Zeitreihen Trends erkennen und vorhersagen. Dies findet Anwendung in vielen Bereichen, zum Beispiel bei der Erkennung eines Drifts in der Qualität von Produktionsprozessen.

Für die Speicherung und Verarbeitung von Zeitreihendaten werden oft spezielle Datenbanken wie InfluxDB verwendet. Diese sind speziell dafür ausgelegt, große Mengen an zeitlich geordneten Daten effizient zu speichern und abzufragen. Solche Datenbanken er-



möglichen es, komplexe Abfragen über lange Zeitreihen hinweg schnell und effizient durchzuführen, was für die Analyse und Verarbeitung durch KI-Systeme unerlässlich ist. ^[34]

Textdaten

Insbesondere durch die steigende Leistungsfähigkeit von Large Language Models (LLMs) haben Textdaten auch für die produzierende Industrie an Relevanz gewonnen. Diese fortschrittlichen KI-Modelle haben die Art und Weise, wie wir mit Sprache und Text umgehen, revolutioniert und eröffnen neue Möglichkeiten in zahlreichen Anwendungsbereichen.

Textdaten umfassen eine breite Palette von Sprachinformationen, von schriftlichen Dokumenten über Onlineartikel bis hin zu sozialen Medien. Die Verarbeitung und Analyse dieser Daten mithilfe von KI-Technologien, insbesondere LLMs, ermöglicht es uns, wertvolle Einblicke zu gewinnen, Muster zu erkennen und komplexe sprachliche Aufgaben zu bewältigen.

Multimodale Datensätze

Multimodale Daten gewinnen zunehmend an Bedeutung. Diese Art von Datensätzen entsteht durch die Kombination von Informationen aus zwei oder mehr verschiedenen Quellen oder Datenformaten, wie Text, Bilder oder relationale Daten. Die Integration dieser vielfältigen Datenquellen ermöglicht es KI-Modellen, ein tieferes und umfassenderes Verständnis eines Problems oder Kontextes zu entwickeln.

Die Nutzung von multimodalen Daten in der KI stellt jedoch eine besondere Herausforderung dar, besonders wenn sie als kombinierter Input in einem Modell verarbeitet werden sollen. Eine der größten Herausforderungen ist die Datenintegration, bei der unterschiedliche Datenformen so kombiniert werden müssen, dass das KI-Modell aus jeder Datenart effektiv lernen kann. Außerdem müssen bei der Synchronisation und Ausrichtung die Daten, die zu verschiedenen Zeiten oder aus verschiedenen Perspektiven erfasst wurden, sinnvoll aufeinander abgestimmt werden.

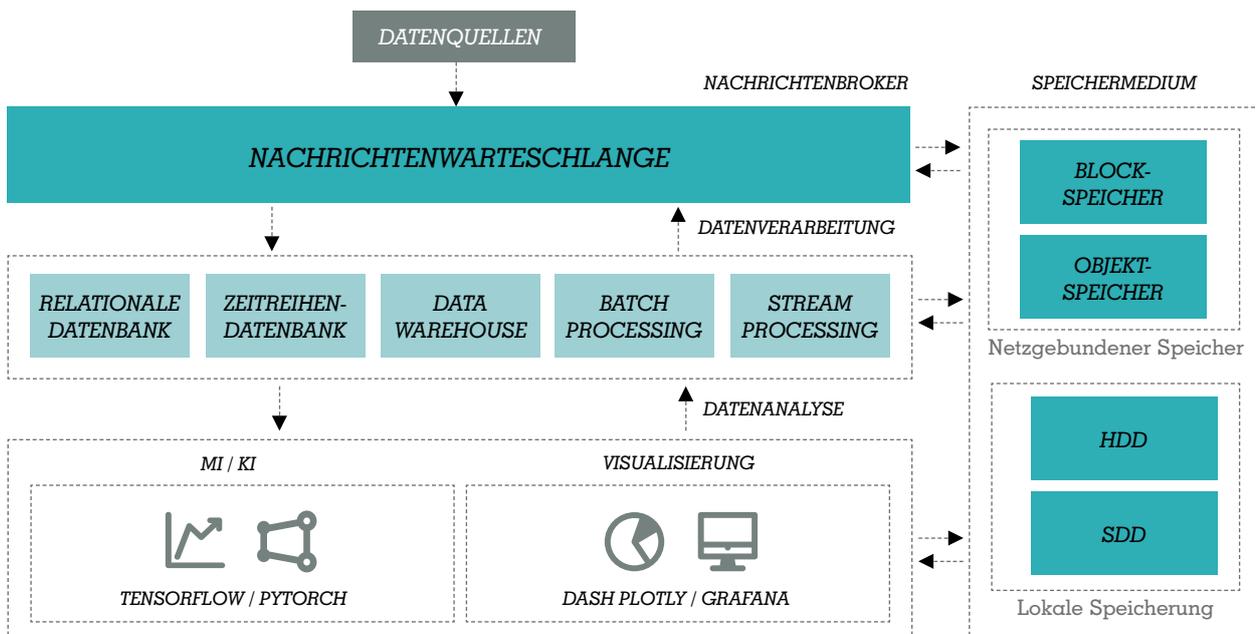


Abbildung 2: Schematische Darstellung einer Dateninfrastruktur und der zugehörigen Datenverwertung mittels KI



Hinzu kommt die Schwierigkeit, die unterschiedlichen Datenstrukturen von Text, Bildern und anderen Medienformen angemessen zu verarbeiten.^[32]

Im Bereich des multimodalen Lernens gibt es verschiedene Ansätze, diese Herausforderungen zu meistern. Einer davon ist die Feature-Level-Fusion, bei der Features (Merkmale) aus verschiedenen Datenquellen zu einem einzigen Satz von Merkmalen zusammengeführt werden, bevor das Modell trainiert wird. Ein anderer Ansatz ist die Entscheidungs-Level-Fusion, bei der mehrere Modelle unabhängig voneinander auf unterschiedlichen Datenformen trainiert und ihre Vorhersagen anschließend kombiniert werden. Darüber hinaus gibt es hybride Modelle, die eine Kombination aus Feature- und Entscheidungs-Level-Fusion nutzen, um die Vorteile beider Methoden zu vereinen.^[35]

Dateninfrastruktur

Varun Pandey

In diesem Abschnitt wird eine mögliche Dateninfrastruktur vorgestellt, die in verschiedenen Branchen, wie auch der Fertigungsindustrie, weit verbreitet ist. Ein Beispiel für eine solche Dateninfrastruktur ist in Abbildung 2 dargestellt. Ein Nachrichtenbroker sammelt zunächst Daten aus verschiedenen Datenquellen. Apache Kafka ist einer der heute am weitesten verbreiteten Nachrichtenbroker. Er hat die Fähigkeit, Daten an verschiedene Speicher- und Datenverarbeitungsmedien zu übertragen. Datenverarbeitungsplattformen können auch Daten für den Benutzer speichern und von Speichermedien abrufen, sodass sich der Benutzer keine Gedanken über die Effizienz oder den Overhead bei der Durchführung dieser Aufgabe machen muss. Die Datenanalyseschicht umfasst Visualisierungsframeworks und Frameworks für maschinelles Lernen oder Deep Learning, die Daten von Datenverarbeitungsframeworks oder Speichermedien abrufen.

Speicherung (Storage)

Die Datenspeicherung ist ein integraler Bestandteil jedes datengesteuerten Prozesses. Derzeit gibt es eine

Vielzahl von Datenspeicherlösungen, die eine breite Palette von Zielen und Anforderungen abdecken. Datenspeicherlösungen basieren häufig auf der Verwendung einer Reihe von Speichermedien oder -geräten wie Festplattenlaufwerken (HDDs) oder Solid State Drives (SSDs). Diese Speichermedien können entweder direkt an den (Computer-)Server angeschlossen werden oder sie können über ein Netzwerk verbunden werden (allgemein als Network Attached Storage oder NAS bezeichnet). Die Lösungen für die Datenspeicherung können auch in die Kategorien „vor Ort“ und „in der Cloud“ eingeteilt werden. Bei der Vor-Ort-Speicherung werden die Daten auf Servern gespeichert, die in den physischen Räumlichkeiten eines Unternehmens (oder im Falle von NAS im Netzwerk) installiert sind, was vollständige Kontrolle, Datenschutz und Sicherheit ermöglicht. Im Gegensatz dazu stützen sich cloudbasierte Lösungen auf Remote-Server, die von Drittanbietern (z. B. Amazon, Google) betrieben werden. Cloudbasierte Lösungen bieten jedoch nahtlose Skalierbarkeit und Benutzerfreundlichkeit. Eine Reihe von Faktoren, darunter Kosten, Sicherheit und Skalierbarkeit, beeinflussen die Entscheidung zwischen diesen beiden Alternativen.

Die Speichermedien bestehen in der Regel aus Rohbytes, die dem Endnutzer zur Datenspeicherung zugänglich sind. In der Regel erfolgt der Zugriff auf diese Rohbytes in Form von Blöcken, Dateien und Objekten. Der Block ist eine inhärente Eigenschaft der Speicherplatte und steht für die Segmente von Bytes, die auf der Platte verfügbar sind. Er ist die kleinste Einheit von Daten, die auf die Festplatte geschrieben werden kann. Daten können auch in Dateien gespeichert werden. Diese Dateien können in Ordnern gruppiert und in einer Hierarchie von Verzeichnissen und Unterverzeichnissen angeordnet werden. Dateien sind in der Regel als Abstraktionen auf Blöcken aufgebaut. Folglich sind Dateien blockbasiert, und Dateisysteme sind in der Regel für die Zuordnung ihrer Datenstrukturen (Verzeichnisse und Dateien) zu Blöcken auf den Speichergeräten verantwortlich. Das Dateisystem ist auch für die Verwaltung von Metadaten im Zusam-



menhang mit Dateien zuständig, z. B. für deren Größe, die Position der Blöcke auf der Festplatte, den Dateityp und andere Aufgaben. Das ist jedoch mit Leistungseinbußen verbunden, da verschiedene Statistiken und Informationen zu Dateien, Verzeichnissen und Unterverzeichnissen verwaltet werden müssen. Daher müssen die Dateien einen Kompromiss zwischen Leistung und Benutzerfreundlichkeit und Vertraulichkeit für den Endbenutzer eingehen. Blöcke ermöglichen einen skalierbaren, schnellen Zugriff auf gemeinsam genutzte Daten und machen einen Dateiserver zur Autorisierung von Ein- und Ausgabe(E/A)-Vorgängen und zur Verwaltung von Metadaten überflüssig. Im Gegensatz dazu ermöglichen Dateien eine sichere, plattformübergreifende gemeinsame Datennutzung, indem sie eine Speicherabstraktion auf höherer Ebene bieten. Es wird allgemein davon ausgegangen, dass Objekte das Beste aus beiden Welten vereinen. Objekte können eine variable Länge haben und sind in der Lage, viele verschiedene Arten von Daten zu speichern, einschließlich, aber nicht beschränkt auf Multimediadaten, Anwendungsdaten, Datenbankeinträge und Dateien in verschiedenen Formaten. So können Objekte sowohl strukturierte (z. B. relationale Datenbanktabellen), halbstrukturierte (z. B. JSON) als auch unstrukturierte (z. B. Bilder, reine Textdateien) Daten speichern. Objektspeicher bieten in der Regel eine Reihe von Anwendungsprogrammierschnittstellen (APIs), die denen eines Dateisystems ähneln und zum Erstellen oder Löschen von Objekten verwendet werden. Da die Größe der Objekte variabel sein kann, ist das Speichergerät in der Regel für die interne Speicherplatzverwaltung der Objekte verantwortlich. Einer der wichtigsten Vorteile der Objektspeicherung ist ihre einfache Bereitstellung und Skalierbarkeit. Das ist einer der Gründe, warum die Objektspeicherung - in größerem Umfang in der Cloud - als grundlegendes Element für zahlreiche Anwendungen und Dienste, einschließlich Datenverwaltungssystemen wie relationalen Datenbanken, Data-Warehouses und Zeitreihendatenbanken usw., erheblich an Popularität gewonnen hat. ^[32]

Eine sichere, geschützte und skalierbare Datenspeicherung kann eine schwierige Aufgabe sein. Daher kann die Datenspeicherung entweder selbst verwaltet oder an verschiedene Datenverwaltungssysteme wie relationale Datenbankverwaltungssysteme (RDBMS) oder Data Warehouses (DW) ausgelagert werden. Auf diese Weise muss sich der Nutzende nicht um die Effizienz der Datenspeicherung und -abfrage kümmern, da diese Systeme die Datenverwaltung auf den verschiedenen Speichergeräten und -technologien übernehmen. Für eine Reihe dieser Systeme gibt es über Angebote verschiedener Cloudanbieter eine native Cloud-Unterstützung. Gegenwärtig gewinnen auch Data Lakes für die Speicherung an Bedeutung. Ein Data Lake bietet dem Benutzer eine einheitliche Sicht auf alle Daten, die strukturiert oder unstrukturiert sein können. Im Allgemeinen werden Data Lakes in Szenarien eingesetzt, die große Datenmengen erzeugen oder beinhalten. Data Lakes basieren in der Regel auf Objektspeichern, da sie in der Lage sind, sowohl strukturierte als auch unstrukturierte Daten zu speichern. Eine wachsende Zahl von cloudnativen Data-Warehouse-Anbietern geht dazu über, ACID-Garantien für massive Data Lakes anzubieten. ACID (atomicity, consistency, isolation, durability) steht für eine Reihe von Eigenschaften, die die Integrität und Zuverlässigkeit von Daten gewährleisten sollen. Es stellt sicher, dass die Gültigkeit der Daten trotz verschiedener Arten von Ausfällen, wie Stromausfällen, Fehlern usw., erhalten bleibt. ^[32]

Verarbeitung (Processing)

Die Datenverarbeitung beinhaltet die Erfassung und Bearbeitung von Daten mit dem Ziel, Wissen zu extrahieren oder aussagekräftige Informationen zu erzeugen. Das Hauptziel besteht darin, Rohdaten in verwertbare Erkenntnisse umzuwandeln, die zur Erleichterung der datengestützten Entscheidungsfindung und Problemlösung genutzt werden können. Die Datenverarbeitung wird heutzutage in einer Vielzahl von Bereichen und Branchen eingesetzt, z. B. in der Automobilindustrie, im Gesundheitswesen, im Marke-



ting, im Finanzwesen, im Einzelhandel oder im E-Commerce. Im Finanzsektor beispielsweise ermöglicht die Datenverarbeitung eine Risikobewertung, Betrugserkennung und effiziente Banktransaktionen. Auch im Marketingbereich ermöglicht die Datenverarbeitung den Unternehmen, mehr über bestimmte Kundengruppen zu erfahren, das Verbraucherverhalten zu verstehen, Werbekampagnen zu starten und die Wirksamkeit dieser Kampagnen durch die Verarbeitung der gewonnenen Daten zu bewerten.

In der Regel gibt es zwei verschiedene Kategorien der Datenverarbeitung: die Stapelverarbeitung und die Echtzeitdatenverarbeitung. Die Stapelverarbeitung ist ein Ansatz, bei dem große Datenmengen in „Stapeln“ gesammelt und verarbeitet werden (z. B. in vorher festgelegten oder geplanten Zeitintervallen). Die Stapelverarbeitung ist besonders nützlich für umfangreiche Datenverarbeitungsaufgaben, bei denen die Daten in kleinere und besser handhabbare Stapel aufgeteilt und gemeinsam verarbeitet werden können. Im Gegensatz dazu entspricht die Echtzeitverarbeitung der sofortigen Verarbeitung von Daten, sobald ein Datenelement, ein Datensatz oder ein Ereignis empfangen wird. Durch die Optimierung der Ressourcennutzung wird bei der Stapelverarbeitung in der Regel ein höherer Durchsatz erzielt. Apache Spark und Apache Hadoop sind zwei Beispiele für Stapelverarbeitungssysteme, während Apache Flink und Apache Storm Systeme für die Verarbeitung von Datenströmen in Echtzeit geeignet sind. ^[32]

Netzwerk (Network)

Das Netzwerk in einer Dateninfrastruktur umfasst Technologien wie Switches, Router und Firewalls. Diese sind notwendig, um die verschiedenen Komponenten der Dateninfrastruktur miteinander zu verbinden und den Datenverkehr zu steuern. Ein leistungsfähiges und sicher konfiguriertes Netzwerk ist entscheidend für die schnelle und sichere Übertragung von Daten zwischen den verschiedenen Elementen der Infrastruktur. Kennwerte, die dabei das Netzwerk beschreiben, sind beispielsweise die Übertragungsrate sowie die Latenzzeit. ^[32]

Rechenleistung (Computing Performance)

Die vorhandene Rechenleistung ist entscheidend dafür, in welchem Umfang KI-Anwendungen trainiert werden können. Es folgt daraus nicht nur, ob das Modell generell trainiert werden kann, beispielsweise durch ausreichend vorhandenen Grafik- oder Arbeitsspeicher, sondern es folgt daraus auch, wie viel Zeit ein Trainingszyklus in Anspruch nimmt. Ferner spielt die vorhandene Rechenleistung für die Effizienz und die Geschwindigkeit in der Ausführung eine Rolle. Moderne Ansätze wie Cloud-Computing ermöglichen es, Rechenressourcen flexibel zu skalieren und damit sowohl kleinen als auch großen Datenprojekten gerecht zu werden. Alternativ kann auch auf lokaler Hardware bzw. Edge Devices trainiert werden. Diese Technologien stellen die notwendige Rechenleistung zur Verfügung, die für komplexe Datenverarbeitungs- und Analyseaufgaben erforderlich ist. Des Weiteren muss je nach Anwendung auch unterschieden werden, welche Bedeutung der GPU (Graphics Processing Unit)- bzw. der CPU (Central Processing Unit)-Rechenleistung zukommt. Während GPUs mit der Fähigkeit, parallele Rechnungen durchzuführen, insbesondere für das Training von KI-Anwendung relevant sind, spielen CPUs bei der Datenverarbeitung sowie der Ausführung und Überwachung von KI-Anwendungen eine entscheidende Rolle. Rechensysteme können dabei nach sogenannten Floating Point Operations per Second (FLOPS) in ihrer Leistung bewertet werden. ^[32]



Sicherheit (Security)

Dateninfrastrukturen müssen sicher sein, um unautorisierten Zugriff und Datendiebstahl zu verhindern. Hierzu werden Technologien wie Verschlüsselung, Zugriffskontrollen und Auditing-Tools eingesetzt. Diese Technologien schützen die Daten selbst, die Netzwerkverbindungen und die Zugriffspunkte der Dateninfrastruktur. Sicherheit ist nicht nur eine technische, sondern auch eine organisatorische Herausforderung und sie muss auf allen Ebenen der Dateninfrastruktur gewährleistet sein. ^[32]

Überwachung und Verwaltung (Monitoring and Management)

Die Überwachung und Verwaltung der Dateninfrastruktur sind entscheidend für den laufenden Betrieb und die Performance. Tools und Technologien wie Dashboards, Alarme und Leistungsindikatoren werden eingesetzt, um den Status der Infrastruktur in Echtzeit zu überwachen. Dadurch können Probleme schnell erkannt und behoben und die Systeme kontinuierlich optimiert werden. ^[36]

Durch ein tiefgehendes Verständnis und die richtige Implementierung dieser sechs Schlüsselbereiche können Organisationen eine robuste, skalierbare und sichere Dateninfrastruktur aufbauen, die den Anforderungen moderner Datenanalyse und -verarbeitung gerecht wird.

Datenqualität

Shahenda Youssef

Im Kern erfolgreicher KI-Anwendungen liegt die Verfügbarkeit und Nutzung von qualitativ hochwertigen Daten. Die Bedeutung der Datenqualität in der KI-Entwicklung kann nicht ausreichend betont werden, da die Wirksamkeit, Genauigkeit und Vertrauenswürdigkeit von KI-Modellen direkt an die Qualität der Daten gebunden sind, auf denen sie trainiert werden.

Die Datenqualität ist aus verschiedenen Gründen von entscheidender Bedeutung und sollte nicht unterschätzt werden:

Genauigkeit und Zuverlässigkeit von Modellen:

KI-Modelle, insbesondere Maschinenlernmodelle, lernen aus Daten. Wenn die Daten Fehler, Voreingenommenheit oder Inkonsistenzen enthalten, werden zwangsläufig auch die resultierenden Modelle diese Mängel aufweisen. Zum Beispiel wird ein überwacht Lernmodell, das mit ungenauen Labels trainiert wird, wahrscheinlich falsche Vorhersagen oder Klassifizierungen produzieren. ^[37, 38]

Ethische Überlegungen: Daten von schlechter Qualität, insbesondere Daten, die Voreingenommenheit enthalten, können zu KI-Modellen führen, die gesellschaftliche Ungleichheiten verstärken oder sogar verschärfen. Zum Beispiel können Gesichtserkennungstechnologien, die hauptsächlich auf Daten einer ethnischen Gruppe trainiert werden, bei anderen schlecht abschneiden, was zu ungerechten Ergebnissen führt.

Betriebliche Effizienz: Die Sicherstellung von qualitativ hochwertigen Daten von Anfang an kann Entwicklungszeiten, Nacharbeit und die finanzielle Belastung im Zusammenhang mit dem Troubleshooting und der Verfeinerung von KI-Modellen später im Entwicklungsprozess reduzieren.

Vertrauenswürdigkeit: Damit Endbenutzer, Stakeholder und Entscheidungsträger KI-gesteuerten Einsichten oder Entscheidungen vertrauen, müssen sie Vertrauen in die zugrunde liegenden Daten haben.

Schlüsseldimensionen der Datenqualität: ^[37]

Vollständigkeit

Vollständigkeit in einem Datensatz bezieht sich darauf, ob alle notwendigen Informationen vorhanden sind. Das wird oft durch den Prozentsatz der fehlenden oder Nullwerte in jedem Attribut des Datensatzes quantifiziert. Wenn beispielsweise in einem Datensatz mit Patienteninformationen häufig das Geburtsdatum fehlt, könnte das ein Anzeichen für eine Lücke in den Daten sein. Das Hauptziel in diesem Bereich ist es, diese Lücken zu identifizieren und Strategien zur Verbesserung der Datenvollständigkeit zu entwickeln.



Konsistenz

Die Konsistenz eines Datensatzes beschreibt, wie gut die Daten über verschiedene Quellen und Zeitpunkte hinweg übereinstimmen. Durch den Vergleich von Daten aus verschiedenen Quellen kann der Prozentsatz der Inkonsistenzen ermittelt werden. Inkonsistente Daten können zu falschen Analysen und Entscheidungen führen. Daher ist es wichtig, die Konsistenz der Daten durch Abgleich und eventuelle Korrektur der Datenwerte und -formate sicherzustellen.

Zugänglichkeit

Die Zugänglichkeit der Daten ist ein entscheidender Faktor für effektive Analysen. Sie wird oft über die durchschnittliche Zeit gemessen, die benötigt wird, um auf die Daten zuzugreifen, sowie über den Prozentsatz der Dateninstanzen, die für autorisierte Benutzer zugänglich sind. Wenn der Datenzugriff zu lange dauert oder nur ein kleiner Prozentsatz der Daten leicht zugänglich ist, behindert das die Analyse erheblich. Das Ziel ist, die Zugänglichkeit der Daten so zu verbessern, dass autorisierte Benutzer sie leicht abrufen können.

Einzigartigkeit

Einzigartigkeit in einem Datensatz bedeutet, dass keine doppelten oder redundanten Informationen vorhanden sind. Das Vorhandensein von Duplikaten kann durch den Prozentsatz der doppelten Instanzen im gesamten Datensatz quantifiziert werden. Duplikate können die Analyse verzerren und zu falschen Schlüssen führen. Deshalb ist es das Ziel, sicherzustellen, dass die Daten einzigartig sind, um eine genaue und unverzerrte Analyse zu ermöglichen.

Validität

Die Validität eines Datensatzes bezieht sich darauf, ob die Daten den vordefinierten Regeln oder Kriterien entsprechen. Eine Quantifizierung erfolgt über den Prozentsatz der Dateninstanzen, die Validierungsprüfungen bestehen. Ungültige Daten können zu unzuverlässigen Analyseergebnissen führen. Daher ist es entscheidend, die Validität der Daten regelmäßig zu

überprüfen und zu verbessern, um die Zuverlässigkeit und Glaubwürdigkeit der datenbasierten Entscheidungsfindung zu erhöhen.

Zuverlässigkeit

Die Zuverlässigkeit eines Datensatzes misst die Genauigkeit und Konsistenz der von verschiedenen Quellen bereitgestellten Daten. Dies kann über Erfolgsraten bei der Datenvalidierung und den Prozentsatz der Dateninstanzen, die Qualitätskontrollen bestehen, beurteilt werden. Ein hoher Grad an Zuverlässigkeit trägt zu einer robusten und vertrauenswürdigen Datenbasis bei, die für eine fundierte Entscheidungsfindung unerlässlich ist.

Integrität

Integrität in einem Datensatz bezieht sich auf die Vollständigkeit, Konsistenz und Genauigkeit der Daten während ihres gesamten Lebenszyklus. Messgrößen können Erfolgsraten bei der Datenvalidierung, den Prozentsatz der Dateninstanzen mit Integritätsproblemen und die Anzahl der erkannten Datenanomalien umfassen. Ein hohes Maß an Integrität gewährleistet, dass die Daten für Analysen und Entscheidungsfindungen verlässlich sind.

Durch das Verständnis und die Anwendung dieser Schlüsselmetriken können Organisationen die Qualität ihrer Daten erheblich verbessern und so bessere und informiertere Entscheidungen treffen.

Vollständigkeit: Fehlen Werte im Datensatz? Unvollständige Daten können zu Fehldarstellungen und Lücken im Verständnis eines KI-Modells führen.

Konsistenz: Daten sollten im gesamten Datensatz konsistent sein, ohne Widersprüche. Inkonsistente Daten können KI-Modelle verwirren und zu unzuverlässigen Ergebnissen führen. Die Integrität der Daten wird unter anderem durch die im Folgenden aufgeführten Aspekte gestärkt oder abgeschwächt.

Genauigkeit: Daten sollten die Realität genau widerspiegeln. Irreführende oder fehlerhafte Daten können KI-Modelle in die Irre führen.



Relevanz: Nicht alle Daten sind möglicherweise relevant. Irrelevante Daten können Rauschen einführen und die Effizienz und Genauigkeit von KI-Modellen verringern.

Aktualität: Insbesondere in dynamischen Umgebungen kann die Verwendung veralteter Daten ein KI-System unwirksam machen.

Unvoreingenommenheit: Daten sollten die Verteilung der realen Welt repräsentieren. Voreingenommene Daten können zu Modellen führen, die verzerrte oder ungerechte Ergebnisse liefern.

Datenprüfungen: Das regelmäßige Bewerten und Prüfen von Datenquellen kann helfen, Qualitätsprobleme zu identifizieren. Das sollte ein kontinuierlicher Prozess während des gesamten KI-Entwicklungszyklus sein.

Vielfältige Datenquellen: Auf mehrere und unterschiedliche Datenquellen zurückzugreifen, kann helfen, einen umfassenderen und unvoreingenommenen Datensatz zu erstellen.

Feedbackschleifen: Die Implementierung von Feedbackmechanismen, bei denen Vorhersagen oder Entscheidungen des KI-Systems überprüft und korrigiert werden, kann im Laufe der Zeit dazu beitragen, die Datenqualität zu verfeinern.

Nutzung von Datenvalidierungstools: Es stehen zahlreiche Tools und Software zur Verfügung, die die Qualität von Daten validieren können und Probleme wie fehlende Werte, Ausreißer oder Inkonsistenzen identifizieren.

Menschliche Aufsicht: Trotz der Vorzüge der Automatisierung ist menschliche Expertise entscheidend für die Bewertung und Gewährleistung der Datenqualität, besonders in kontextabhängigen Szenarien.

Zusammenfassend ist die Datenqualität grundlegend in der KI-Entwicklung. Die Sicherstellung von qua-

litativ hochwertigen Daten wird nicht nur zu einer technischen Notwendigkeit, sondern auch zu einem ethischen Gebot. Organisationen, die die Datenqualität priorisieren, werden besser in der Lage sein, das transformative Potenzial der KI zu nutzen, während sie Risiken minimieren.



BEWERTUNG UND NUTZUNG DER KI-ANWENDUNGEN IM ARBEITSUMFELD

Felipa Carrara, Elena Freisinger (Fachgebiet Innovationsmanagement an der Fakultät für Wirtschaftswissenschaften und Medien an der Technischen Universität Ilmenau), Sabine Pfeiffer, Bruno Albert, Silke Röbenack und Romy Blinzler (Lehrstuhl für Soziologie mit dem Schwerpunkt Technik – Arbeit – Gesellschaft am Institut für Soziologie an der Friedrich-Alexander-Universität Erlangen-Nürnberg)

Im Kapitel „Soziales und organisationales Umfeld von KI-Anwendungen“ wurde bereits ausgeführt, dass die Partizipation der Beschäftigten eine zentrale Rolle bei der erfolgreichen Einführung von KI spielt. Eine gelingende Partizipation korrespondiert dabei mit zwei Aspekten: zum einen mit der Problematik der Akzeptanz von KI-Technologien und zum anderen mit der Frage, welche (vorhandenen) KI-relevanten Kompetenzen aufseiten der Beschäftigten für die Einführung und dauerhafte Nutzung von KI genutzt und weiterentwickelt werden können. Beide Aspekte, die im folgenden Kapitel umrissen werden, sind in ihrer Bedeutung für die Implementierung und die Entfaltung des Nutzenpotenzials von KI-Technologien nicht zu unterschätzen.

Managerial Summary:

Ob und wie Nutzende KI-basierte Systeme akzeptieren, beeinflusst die Nutzung und damit die Realisierung der Erfolgspotenziale der Systeme. Eine Ablehnung von KI-basierten Systemen kann zu Fehlgebrauch, Missbrauch oder Nichtnutzung^[39, 40] und damit letztlich minderwertigen Entscheidungen führen. Dabei sind die Gründe einer potenziellen Ablehnung vielschichtig und beziehen sich auf die Eigenschaften KI-basierter Systeme (bspw. die Aufgaben der Systems) wie auch auf die Eigenschaften der Nutzenden (bspw. Erfahrungswerte im Umgang mit KI-basierten Systemen). Für eine erfolgreiche Einführung von KI-basierten Systemen

und die Realisierung potenzieller Erfolgsfaktoren ist es wichtig sich gleichermaßen mit den Eigenschaften des KI-basierten Systems und den Eigenschaften der Nutzenden auseinanderzusetzen.

Ein wichtiger Erfolgsfaktor für die Realisierung der potenziellen Vorteile von KI-basierten Systemen ist die Akzeptanz der Nutzenden, die täglich mit dem System interagieren. Bisherige Studien des Forschungsfeldes haben gezeigt, dass Menschen oft widerwillig oder abgeneigt auf die Verwendung von KI-basierten Entscheidungen reagieren (z. B. Burton et al.^[39]). Zielsetzung dieses Kapitels ist es, Faktoren darzulegen, die die Nutzung und Akzeptanz von KI-basierten Systemen beeinflussen. Zudem werden Handlungsempfehlungen abgeleitet, um das Nutzungs- und Einstellungsverhalten von Mitarbeitenden gegenüber KI-basierten Systemen positiv zu beeinflussen.

Handlungsempfehlungen

Kommunikation & Information: Eine frühzeitige Kommunikation über die Einführung KI-basierter Systeme sowie Schulungsformate zu Anwendung und Funktionsweise des Systems können dabei helfen, anfängliche Widerstände von Mitarbeitenden abzubauen.

Transparenz & „Walk the talk“: Eine klare und verbindliche Definition und Kommunikation des Einführungsprozesses KI-basierter Systeme können das Vertrauen der Mitarbeitenden stärken.



Strukturierte Begleitung des Changeprozesses:

Eine frühzeitige Einbindung der Mitarbeitenden in den Changeprozess kann helfen, mögliche Widerstände von Mitarbeitenden gegenüber KI-basierten Systemen abzubauen.

Akzeptanz von KI

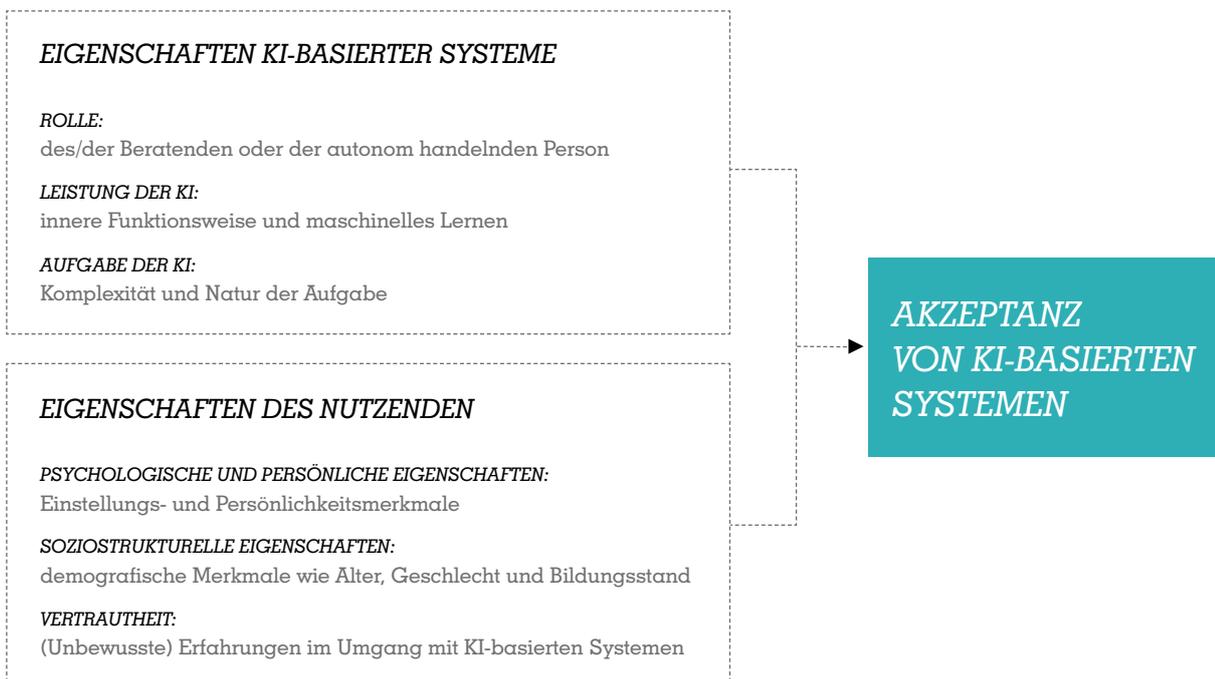
Felipa Carrara und Elena Freisinger

Die Akzeptanz von KI-basierten Systemen ist entscheidend für das Erfolgspotenzial der Mensch-KI-Interaktion.^[41, 42] Neben der Miteinbeziehung der Beschäftigten in den Prozess der KI-Implementierung, siehe „Soziales und organisationales Umfeld von KI-Anwendungen“, ist es daher unerlässlich, sich zudem mit dem Akzeptanzverhalten der Nutzenden auseinanderzusetzen. Nur unter dieser Voraussetzung können die angestrebten Nutzenpotenziale der KI-basierten Systeme verwirklicht und eine Ablehnung, die zu Fehlgebrauch, Missbrauch oder Nichtnutzung führen kann,^[39, 40] vermieden werden.

Obwohl die Sicherstellung der Akzeptanz von KI-basierten Systemen auf den ersten Blick trivial erscheinen mag, gestaltet sich diese in der Umsetzung jedoch äußerst komplex, da eine Vielzahl an Faktoren zu berücksichtigen sind, die Akzeptanz oder auch mögliche Aversionen gegenüber KI-basierten Systeme beeinflussen.^[41]

Im Gegensatz zu bekannten Akzeptanzmodellen von Technologien, wie bspw. TAM (Technology Acceptance Model)^[43] oder UTUAT (Unified Theory of Acceptance and Use of Technology)^[44] gestaltet sich das Akzeptanzverhalten gegenüber KI-basierte Systeme wesentlich komplexer, da sie sich vor allem durch ihre Autonomie, ihrer leistungsstarken Lernfähigkeiten sowie ihrer Unergründlichkeit und Unvollkommenheit von herkömmlichen Technologien unterscheiden. Wesentliche Faktoren bei der Akzeptanz von KI-basierten Systemen nehmen dabei die Eigenschaften der des Systems selbst und die des Nutzenden ein (siehe Abbildung 3). Um die Akzeptanz KI-basierter Systeme von Mitarbei-

Abbildung 3 Eigenschaften von KI-basierten Systemen und der Nutzenden, die die Akzeptanz von KI-basierten Systeme beeinflussen, eigene Darstellung i. A. an. [41]





tenden sicherzustellen bzw. zu fördern, muss man sich demnach ausgiebig mit den Charakteristiken der Mitarbeitenden und jener des Systems selbst beschäftigen.

Eigenschaften KI-basierter Systeme

Jene Eigenschaften KI-basierter Systeme, die die Akzeptanz von KI beeinflussen, umfassen die Rolle, die Leistungen und die Aufgaben der KI und das Maß menschlichen Eingreifens, siehe Abbildung. Rolle KI-basierter Systeme.

Die Rollenverteilung zwischen Mensch und KI ist ein entscheidender Faktor, der die Akzeptanz maßgeblich beeinflusst. Menschen bevorzugen in der Regel menschliche Entscheidungen, die von KI-basierten Systemen unterstützt werden, und verlassen sich eher auf KI-basierte Systeme, solange diese den Menschen untergeordnet sind und die endgültigen Entscheidungen von Menschen getroffen werden.^[45] Menschen sind zudem eher bereit, KI-basierte Systeme anzunehmen, wenn sie sich nicht von ihnen bedroht fühlen. Wenn KI-basierte Systeme beispielsweise darauf abzielen, menschliche Entscheidungen oder Fähigkeiten vollständig zu ersetzen, sind Menschen weniger bereit, sie anzunehmen. Hingegen verlassen sie sich eher auf KI-basierte Systeme, die dem Menschen untergeordnet sind.^[46, 47]

Erwartungshaltung gegenüber KI-basierten Systemen

Die Erwartung an die Leistungen KI-basierter Systeme spielt eine weitere entscheidende Rolle dafür, wie Nutzende mit den Systemen interagieren und sie bewerten. Mehrere Studien liefern Hinweise darauf, dass Nutzende Schwierigkeiten mit Fehlfunktionen haben. Nutzende sind häufig davon überzeugt, dass KI-basierte Systeme einwandfrei sind und keine Fehler machen.^[48-50] Wenn sie jedoch feststellen, dass KI-basierte Systeme fehlerhaft sind, neigen sie dazu, die Systeme für die Nichterfüllung ihrer Erwartungen verantwortlich zu machen. Daher ist es wahrscheinlich, dass Menschen höhere Erwartungen an die Genauigkeit und Konsistenz der Leistung von KI-basierten Systemen

als an die Genauigkeit und Konsistenz der Leistung von Menschen haben.

Aufgaben der KI

Studien belegen, dass die Aufgaben KI-basierter Systeme, deren Komplexität und Urteilsvermögen, das Akzeptanzverhalten der Nutzenden ebenfalls sehr beeinflussen.^[41] Beispielsweise zögern Menschen Entscheidungen von KI-basierten Systemen anzunehmen, die moralischer Natur sind und ein gewisses Maß an Menschlichkeit^[47] oder Subjektivität^[51, 52] erfordern. Hingegen werden KI-basierte Systeme eher akzeptiert, die über einen hohen Nutzen verfügen. Dieser wahrgenommene Nutzen der KI-basierten Systeme gilt als einer der stärksten Prädiktoren für die Verhaltensabsicht des Nutzenden.^[44]

Charakteristika der Nutzenden

Das Erfolgspotenzial von KI-basierten Systemen beruht nicht nur auf dem Design und den Aufgaben des Systems selbst, sondern gleichermaßen auf den Interaktionen mit den Nutzenden. Demnach empfehlen wir Unternehmen, sich nicht nur ausgiebig der Programmierung und der Gestaltung des KI-basierten Systems selbst, sondern ebenso mit der Beschaffenheit und den Bedürfnissen der Nutzergruppen auseinanderzusetzen. Dabei kann die Beschaffenheit durch psychologische, persönliche und soziostrukturelle Faktoren beschrieben werden sowie durch Erfahrungen im Umgang mit KI-basierten Systemen.

Psychologische und persönliche Faktoren

Mit psychologischen Faktoren sind die Faktoren gemeint, die mit individueller Logik, Denken und Emotionen im Zusammenhang mit KI-basierten Systemen stehen. Einige Menschen sind per se abgeneigt gegenüber KI-basierten Systemen, ohne die Vorzüge solcher Systeme zu kennen.^[53-55] Diese Abneigungen können häufig auf ein allgemeines Misstrauen zurückgeführt werden, das sich aus der negativen Wahrnehmung von KI-basierten Systemen ergibt^[56] oder auf einen Mangel an emotionalem Vertrauen^[46] bzw. auch auf eine



inhärente Angst gegenüber Veränderungen.^[55]

Zu den Persönlichkeitseigenschaften, die das Akzeptanzverhalten von KI beeinflussen, gehören beispielsweise Faktoren der Selbstüberschätzungen^[57] und Persönlichkeitsmerkmale wie Offenheit, Gewissenhaftigkeit, Extraversion, Verträglichkeit und Neurotizismus (diese Persönlichkeitsmerkmale sind dem „Big Five“-Persönlichkeitsmodell zugehörig, das in der Persönlichkeitspsychologie universell anerkannt ist).

Soziostrukturelle Faktoren

Soziostrukturelle Merkmale einer Person beziehen sich auf die individuellen Eigenschaften und Merkmale, die in Bezug auf die soziale Struktur einer Gesellschaft relevant sind wie bspw. Alter, Geschlecht und Bildungsniveau. Menschen aus verschiedenen Alters-, Geschlechter- und Bildungsgruppen akzeptieren und interagieren unterschiedlich mit KI-basierten Systemen. So nehmen ältere Menschen KI-basierte Systeme beispielsweise als weniger nützlich wahr^[58] und vertrauen ihnen weniger.^[59] Ebenso schätzen Menschen KI-basierte Systeme weniger, wenn ihr Bildungsniveau niedriger ist und wenn sie sich mit Zahlen weniger wohl fühlen.^[60,61]

Vertrautheit mit KI

Die bisherige Vertrautheit von Menschen mit KI-basierten Systemen hat einen signifikanten Einfluss auf die Nutzung von den Systemen. So führt bspw. eine mangelnde Vertrautheit gegenüber KI-basierten Systemen zu einer höheren Abneigung und einer niedrigen Akzeptanz.^[41] Dennoch kann die Vertrautheit ambivalent sein: Auf der einen Seite kann eine gewisse Vertrautheit mit KI-basierten Systemen eine bestehende Abneigung verringern, auf der anderen Seite kann sie kontraproduktiv sein, wenn die Vertrautheit negativer Art ist, etwa, wenn Nutzende schlechte Erfahrungen mit KI-basierten Entscheidungen gemacht haben. Die Vertrautheit bezieht sich dabei nicht nur auf die Erfahrungen selbst, sondern ebenso auf die Häufigkeit des Verwendens des KI-basierten Systems.^[53]

Kompetenzen

Sabine Pfeiffer, Bruno Albert, Silke Röbenack und Romy Blinzler

Managerial Summary:

- KI-Systeme erfordern von den Beschäftigten neue Kompetenzen, die zum Teil neu erworben werden müssen, zum Teil aber auch an bestehendes Wissen anknüpfen können.
- Eine Reihe von Tätigkeiten in der Produktion verlangt bereits Programmierkenntnisse sowie ein mathematisches und/oder statistisches Grundverständnis, das sich mit wenig Aufwand in Richtung einer spezifischen KI-Kompetenz weiterentwickeln lässt.
- Für den produktiven Einsatz aktueller KI-Technologien in stark von Komplexität und Wandel geprägten Anwendungsbereichen ist es nützlich, die Ergebnisse von KI-Anwendungen in den fachlichen Kontext einordnen zu können. Beschäftigte in solchen Bereichen bringen oft eine fundierte Kontext-Kompetenz mit, die sowohl für die Implementierung als auch dauerhafte Anwendung von KI systematisch genutzt werden sollte.

Wie empirische Untersuchungen zeigen, erfordert der Einsatz von KI in der Produktion von den Beteiligten eine Vielzahl von Kompetenzen [17]. Der Einsatz von KI in der Produktion erfordert von den Beteiligten eine Vielzahl von Kompetenzen. Dabei sind nicht nur KI-spezifische Programmierkenntnisse der Expert*innen erforderlich; vielmehr verlangt ein Einsatz von KI in der Produktion auch von den Beschäftigten neue Kompetenzen: Sie müssen die Potenziale und Grenzen von KI-Technologien in ihrem Arbeitsfeld verstehen (KI-Kompetenz) und in der Lage sein, KI-Systeme und ihre Ergebnisse in den fachlichen Kontext einzuordnen (Kontext-Kompetenz).

Es müssen nicht alle Kompetenzen von den Beschäftigten neu erworben werden. Daher ist es sinnvoll zu prüfen, über welche Kompetenzen die Beschäftigten bereits verfügen, die für den Einsatz von KI in der



Produktion genutzt werden können. Diese Kompetenzen müssen nicht notwendigerweise über formale Bildungsprozesse mit entsprechenden Zertifikaten erworben worden sein, sondern können ebenso einschlägige Kenntnisse und Fähigkeiten umfassen, die im täglichen Arbeitshandeln angeeignet wurden.

Im Hinblick auf KI-Kompetenz ist es hilfreich, wenn Beschäftigte bereits über vertiefte IT-Kenntnisse in Verbindung mit mathematischem und/oder statistischem Verständnis verfügen: Eine Reihe von Tätigkeiten in der Produktion erfordern Programmierkenntnisse (z. B. CNC-Programmierung), und Beschäftigte, die eine Weiterbildung im Bereich der Qualitätssicherung absolviert haben, bringen darüber hinaus Kenntnisse in statistischen Methoden mit (z. B. Stichprobenziehung). In beiden Fällen kann an bereits bestehende Kompetenzen angeknüpft und die Beschäftigten mit relativ geringem Aufwand in Richtung systematischer KI-Kompetenz qualifiziert werden. Die vorhandenen Grundkenntnisse sind zum einen hilfreich, um einen produktiven Umgang mit KI in der Produktion sicherzustellen, und zum anderen, um eine gemeinsame Sprache mit den IT-Expert*innen, die mit der Einführung von KI betraut sind, herzustellen.

Die besonderen Anforderungen und/oder die Komplexität des Anwendungskontextes von KI-Technologien werden ebenso häufig unterschätzt wie das Potenzial des kontextbezogenen Wissens der Beschäftigten: Dabei stoßen aktuelle KI-Anwendungen gerade in komplexen, von Wandel und Unwägbarkeiten geprägten Bereichen schnell an immanente Grenzen. Insofern ist die sinnvolle Einführung wie auch der dauerhafte Einsatz von KI-Technologien zwingend auf die Kontextualisierung durch Menschen angewiesen, die den komplexen und dynamischen Anwendungskontext kennen und mit den Unwägbarkeiten umgehen können. Eine hohe Kontext-Kompetenz ist hilfreich, um die Ergebnisse der KI-Anwendungen an den fachlichen Kontext zurückbinden zu können. Beschäftigte mit hoher Kontext-Kompetenz sind daher systematisch in die Umsetzung von KI-Anwendungen einzubeziehen. Anknüpfend an die bereits vorhandenen Kompetenzen sollten Weiterbildungsangebote bereitgestellt werden, um die Wissensbasis zu schaffen, die es ermöglicht, Beschäftigte in der Produktion partizipativ in die Einführung und Anwendung von KI einzubinden.^[17]



PLANUNG DER EINFÜHRUNG VON KI-ANWENDUNGEN

Shahenda Youssef (Karlsruher Institut für Technologie, Lehrstuhl für Interaktive Echtzeitsysteme)
Rezaul Abedin, Tim Cofala und Raneen Younis (Leibniz Universität Hannover, Forschungszentrum L3S)

Managerial Summary:

KI verändert die Fertigungsindustrie unter anderem durch Effizienzsteigerungen, reduzierte Ausfallzeiten und verbesserte Qualitätskontrollen. Ein strukturierter Ansatz, wie CRISP-DM, hilft, KI-Projekte erfolgreich und zielgerichtet umzusetzen. Die sechs Phasen des CRISP-DM (Geschäftsverständnis, Datenverständnis, Datenvorbereitung, Modellierung, Bewertung und Bereitstellung) werden in diesem Kapitel genauer dargestellt. Neben der eigenständigen Entwicklung von KI-Anwendungen besteht für Unternehmen jedoch auch die Möglichkeit, Anwendungen zuzukaufen oder entwickeln zu lassen. Fertige Lösungen sind schnell und kosteneffizient, bieten jedoch weniger Anpassungsmöglichkeiten. Maßgeschneiderte Lösungen bieten Flexibilität und Wettbewerbsvorteile, erfordern aber mehr Zeit, Know-how und Ressourcen. Die Wahl hängt von den spezifischen Unternehmenszielen, Kompetenzen und Anforderungen ab, mit dem Ziel, KI optimal zur Steigerung der Effizienz und Wettbewerbsfähigkeit einzusetzen.

Planung der KI-Entwicklung

Shahenda Youssef

Das wachsende Feld der KI hat zahlreiche Branchen verändert und Möglichkeiten für Innovationen und Lösungen eröffnet, die zuvor als unvorstellbar galten. Angesichts der Komplexität von KI-Projekten besteht jedoch ein dringender Bedarf an strukturierten, robu-

ten Methoden, die erfolgreiche Ergebnisse gewährleisten. Ein solcher Ansatz ist der Cross-Industry Standard Process for Data Mining (CRISP-DM), der einen strukturierten Ansatz für die Planung, Organisation und Durchführung von Data-Mining-Projekten bietet. Der CRISP-DM umfasst sechs Hauptphasen: Geschäftsverständnis (Business Understanding), Datenverständnis (Data Understanding), Datenvorbereitung (Data Preparation), Modellierung (Modeling), Bewertung und (Evaluation), Bereitstellung (Deployment). ^[62,63]

1. Business Understanding

In dieser ersten Phase geht es darum, die Ziele und Anforderungen des Projekts aus der Unternehmensperspektive zu verstehen:

Definition des Problems: Verstehen der geschäftlichen Anforderungen und ihre Umsetzung in Data-Mining-Ziele, um effektive Entscheidungsfindung und Mehrwertgenerierung durch Data Mining und KI zu ermöglichen.

Bewertung der aktuellen Situation: Dazu gehört das Verständnis der vorhandenen Ressourcen, Einschränkungen, Annahmen und anderer relevanter Faktoren.

Bestimmen der Erfolgskriterien des Unternehmens: Was macht das Projekt aus geschäftlicher Sicht zu einem Erfolg? Beispiele für Erfolge sind eine Umsatzsteigerung oder eine Kostenreduzierung.



2. Data Understanding

In dieser Phase wird versucht, das Projektteam mit den Daten vertraut zu machen, um ein Verständnis für ihren Inhalt, ihre Qualität und ihre Struktur zu erlangen:

Datensammlung: Erstes Sammeln von Daten und Bestimmen ihrer Zugänglichkeit.

Datenbeschreibung: Verwendung von grundlegenden statistischen Maßnahmen zur Beschreibung der Daten und zur Erfassung ihrer Qualität.

Datenexploration: Verwendung von visuellen und statistischen Methoden, um erste Erkenntnisse zu gewinnen und die Beziehungen zwischen den Variablen zu verstehen.

Überprüfung der Datenqualität: Erkennen von Problemen in Bezug auf die Datenqualität, etwa fehlende Werte, Ausreißer oder Inkonsistenzen.

3. Data Preparation

Die Datenvorbereitung ist oft die zeitintensivste Phase und umfasst alles, was zur Erstellung des endgültigen Datensatzes für die Modellierung erforderlich ist:

Datenbereinigung:

Behandlung fehlender Werte: Je nach Art der Daten und des Problems können Sie fehlende Werte mit Techniken wie Mittelwert, Median, Modus oder fortgeschrittenen Methoden wie der k-NN-Imputation vervollständigen.

Entfernen von Duplikaten: Doppelte Einträge können zu Verzerrungen führen, daher sollten sie identifiziert und entfernt werden.

Erkennung und Behandlung von Ausreißern: Ausreißer können die Modellergebnisse verfälschen. Je nach Kontext können Ausreißer entfernt, gekappt oder angepasst werden.

Umwandlung der Daten:

Das kann Normalisierung, Aggregation oder andere Techniken umfassen, um die Daten für die Modellierung geeignet zu machen.

Normalisierung: Skalierung von Merkmalen mit einem Mittelwert von 0 und einer Standardabweichung von 1. Nützlich für Algorithmen, die empfindlich auf Merkmalskalamen reagieren.

Standardisierung: Skalierung von Merkmalen, sodass sie zwischen einem bestimmten Minimal- und Maximalwert liegen, häufig zwischen 0 und 1.

One-hot-Codierung: Ein Verfahren zur Konvertierung kategorischer Variablen in eine Form, die von Maschinenlernalgorithmen zur Verfügung gestellt werden kann, indem binäre Variablen erstellt werden, die jede Kategorie repräsentieren.

Merkmalstechnik: Erstellung neuer Merkmale auf der Grundlage der vorhandenen Merkmale. Dabei wird das Fachwissen des jeweiligen Bereichs genutzt, um zusätzlichen Kontext oder Informationen hinzuzufügen, was zu einer verbesserten Datenrepräsentation und einer effizienteren Analyse führt.

Datenreduzierung:

Dimensionalitätsreduzierung: Techniken wie die Hauptkomponentenanalyse oder Autoencoder können eingesetzt werden, um die Anzahl der Merkmale zu reduzieren, wenn der Datensatz zu groß ist, wodurch ein schnelleres Training ohne großen Informationsverlust gewährleistet wird.

Merkmalsauswahl: Hier geht es um die Auswahl der wichtigsten Merkmale, die zur Vorhersage beitragen. Die Techniken können so einfach sein wie Korrelationsmatrizen oder fortgeschrittener wie die rekursive Feature-Elimination.

Umgang mit unausgewogenen Daten:

Strategien zur Bewältigung von Datensätzen, bei denen die Verteilung der Klassen oder Labels nicht gleichmäßig ist.

Oversampling: Erhöhen der Anzahl der Instanzen in der Minderheitsklasse durch zufällige Wiederholungen.

Undersampling: Verringern der Anzahl der Instanzen in der Mehrheitsklasse durch zufällige Löschung dieser Instanzen.



Synthetische Datengenerierung: Methoden wie die Synthetic Minority Over-sampling Technique (SMOTE) können verwendet werden, um synthetische Beispiele im Merkmalsraum zu erzeugen.

Aufteilung der Daten:

Trainings-, Validierungs- und Testgruppen: Die Daten werden normalerweise in diese Teilmengen aufgeteilt. Der Trainingsatz dient zum Trainieren des Modells, der Validierungssatz zur Abstimmung der Hyperparameter und der Testsatz zur Bewertung der Modellleistung.
Stratifizierung: Um sicherzustellen, dass jede Teilmenge eines unausgewogenen Datensatzes das gleiche Verhältnis der Klassen beibehält, werden Proben aufgeteilt, wobei das Verhältnis der Klassen in jeder Teilmenge proportional zur Gesamtdatenverteilung bleibt. Das gewährleistet, dass kein Bias entsteht und alle Klassen angemessen repräsentiert sind, was die Zuverlässigkeit und Genauigkeit der Analyse erhöht.

Datenintegration:

Wenn die Daten aus verschiedenen Datensätzen stammen, müssen sie in ein kohärentes Format integriert werden.

4. Modeling

Im Anschluss an die Datenvorbereitung konzentriert sich diese Phase auf die Entwicklung und Kalibrierung verschiedener Modelle:

Auswahl der Modellierungstechniken: Auswahl geeigneter Algorithmen auf der Grundlage des jeweiligen Problems, z. B. Klassifizierung, Regression, Clustering, Zeitreihen usw.

Modellbildung: Trainieren von Modellen unter Verwendung der gewählten Techniken.

Bewertung des Modells: Verwendung vordefinierter Modellbewertungskriterien zur Beurteilung der Modelle.

5. Evaluation

Bevor das Modell zum Einsatz kommt, wird seine Fähigkeit, die Unternehmensziele zu erreichen, gründlich bewertet:

Bewertung des Modells: Bewertung des Modells anhand der in der ersten Phase festgelegten Unternehmensziele.

Überprüfung des Prozesses: Rückblick und Überprüfung der Schritte, die während der Datenaufbereitung und der Modellierungsphase unternommen wurden.

Festlegung der nächsten Schritte: Der nächste Schritt könnte sein, zu entscheiden, ob man das Modell einsetzt oder ob man weitere Verfeinerungen vornimmt oder ob man eine neue Datenerhebung initiiert.

6. Deployment

Das Hauptziel besteht darin, die durch KI gewonnenen Erkenntnisse in die Praxis umzusetzen:

Planung des Einsatzes: Das umfasst die Entwicklung einer Strategie zur Integration der Data-Mining-Erkenntnisse in das bestehende System.

Planung der Überwachung und Wartung: Da sich Modelle im Laufe der Zeit verschlechtern können, müssen sie regelmäßig abgestimmt und aktualisiert werden.

Wenn Unternehmen diese Phasen von CRISP-DM befolgen, können sie sicherstellen, dass ihre KI-Projekte umfassend und robust sind und mit den Geschäftszielen übereinstimmen. ^[62,63]



Make-or-Buy-Entscheidungen treffen

Rezaul Abedin, Tim Cofala und Rameen Younis

KI-Lösungen für industrielle Produktionssysteme können Wartungsarbeiten vorhersagen, Ausfallzeiten reduzieren und Qualitätskontrollen durchführen. Dies wird durch die Verarbeitung von Sensor- oder Maschinendaten oder von weiteren IoT-Geräten umgesetzt. Daten wie Druck, Temperatur oder Position werden erfasst, vorverarbeitet und analysiert.

Ein kleiner Funktionsumfang wird bereits von Industrielösungen geleistet. Der Einsatz von KI-Lösungen in der Fertigungsindustrie bringt eine Reihe von Vorteilen mit sich. Erstens verbessert die KI die Produktionseffizienz durch Echtzeitüberwachung und -steuerung, was zu geringeren Ausfallzeiten und weniger Ausschuss führt. Zweitens erleichtert sie die vorausschauende Wartung. Dadurch wird sichergestellt, dass Maschinen und Anlagen gewartet werden, bevor sie ausfallen, wodurch kostspielige Unterbrechungen der Produktionslinie unterbunden werden. Darüber hinaus können KI-gesteuerte Qualitätskontrollsysteme Fehler und Anomalien mit größerer Genauigkeit erkennen, was Produktfehler reduziert und die Produktqualität insgesamt verbessert. Einer größeren Komplexität an Anforderungen kann man eher mit Eigenentwicklungen begegnen, da die notwendige Flexibilität und Anpassungsfähigkeit in der Produktion und schnelle Anpassungen an sich ändernde Marktanforderungen sich durch bestehende KI-Lösungen schwieriger umsetzen lassen.

Um diese Ziele zu erreichen, kommen erwerbbar KI-Lösungen in der Industrie bereits zum Einsatz. Beispielsweise bieten diese Lösungen vorausschauende Wartung für CNC-Maschinen an, die Motorausfälle vermeiden und Ausfallzeiten reduzieren. Auch gibt es Industrielle IoT-Plattformen, die Datenanalyse, vorausschauende Wartung und Prozessoptimierung durchführen. Wieder andere bestehende Lösungen fokussieren sich auf Qualitätskontrolle, Wartung, der

Verbesserung der Lieferkette oder dem Performance-Management durch vorausschauende Wartung von Industrieanlagen.

Die Entscheidung zwischen dem Kauf von fertigen KI-Lösungen und der internen Entwicklung individueller KI-Lösungen ist eine wichtige Entscheidung, die erhebliche Auswirkungen auf die betriebliche Effizienz, Kosteneffizienz und Wettbewerbsfähigkeit der Fertigungsindustrie haben kann. Mehrere kritische Faktoren, darunter Anpassungsanforderungen, Budgetbeschränkungen, vorhandene Kompetenzen, zeitliche Ressourcen, laufende Wartung und Skalierbarkeit, stehen im Mittelpunkt des Entscheidungsprozesses. Eine vergleichende Analyse der beiden Ansätze beleuchtet die Vor- und Nachteile und liefert Erkenntnisse, die der Fertigungsindustrie helfen, diese kritische Entscheidung zu treffen und das transformative Potenzial der KI für die Optimierung ihrer Prozesse zu nutzen.

Der Kauf von fertigen KI-Tools hat oft Vorteile, vor allem für kleinere Unternehmen, die nur über begrenzte Ressourcen verfügen. Diese vorgefertigten Lösungen sind in der Regel schneller zu implementieren und erfordern weniger Vorlaufkosten für die Entwicklung. Sie werden mit etablierten Support- und Wartungssystemen geliefert, die Zuverlässigkeit gewährleisten und Belastungen der internen IT-Teams verringern. Das kann zu Kosteneinsparungen und einer schnelleren Kapitalrendite führen, was besonders für kleine und mittlere Unternehmen (KMU) wichtig ist, die ihre Produktionsprozesse ohne große Investitionen verbessern wollen. Darüber hinaus bieten fertige KI-Tools Zugang zu Spitzentechnologie und bewährten Verfahren, da sie häufig von Experten mit umfassenden Branchenkenntnissen entwickelt werden.

Für eine solche schnellere und kosteneffizientere Einführung von KI-Lösungen sind allerdings Abstriche in der Individualisierbarkeit hinzunehmen. Vor-



gefertigte Lösungen sind für ein breites Publikum konzipiert, und obwohl sie sich mit den allgemeinen Herausforderungen der Branche befassen, müssen sie möglicherweise besser auf die speziellen Produktionsprozesse und Ziele eines bestimmten Unternehmens abgestimmt werden. Die Anpassungsmöglichkeiten sind oft was, welche eine Abstimmung auf die Bedürfnisse der Fertigungseinrichtung beeinträchtigen kann. In Fällen, in denen es einzigartige Prozesse oder Anforderungen gibt, können vorgefertigte Lösungen unzureichend sein und zu suboptimalen Ergebnissen führen. Im Gegensatz dazu bietet die interne Entwicklung maßgeschneiderter KI-Lösungen mehr Flexibilität und Anpassungsfähigkeit. Mit diesem Ansatz können Unternehmen KI-Lösungen erstellen, die auf die einzigartigen Herausforderungen und Ziele ihrer jeweiligen Fertigungsprozesse zugeschnitten sind. Maßgeschneiderte Lösungen können nahtlos in bestehende Systeme und Arbeitsabläufe integriert werden und gewährleisten so einen kohärenten und umfassenden Ansatz für die KI-Implementierung. Dieser Grad der Anpassung ist von unschätzbarem Wert für Unternehmen mit hochspezialisierten Prozessen oder solche, die sich durch innovative KI-Lösungen einen Wettbewerbsvorteil verschaffen wollen. Außerdem bietet sie die volle Kontrolle über den Entwicklungsprozess und ermöglicht Anpassungen und Erweiterungen, wenn sich die Produktionsanforderungen weiterentwickeln.

Die Entwicklung individueller KI-Lösungen bringt jedoch eine Reihe von Herausforderungen mit sich. Sie erfordert in der Regel eine erhebliche Anfangsinvestition in Zeit und Ressourcen, einschließlich der Einstellung oder Schulung von KI-Experten. Der Entwicklungsprozess kann zeitaufwendig sein, was die Realisierung der Vorteile von KI möglicherweise verzögert. Darüber hinaus sollten Unternehmen, die sich für eine interne Entwicklung entscheiden, darauf vorbereitet sein, sich mit Fragen der laufenden Wartung und Skalierbarkeit auseinanderzusetzen. Dazu gehört auch, die KI-Lösungen auf dem neuesten Stand

zu halten, um sicherzustellen, dass sie mit der sich verändernden Technologielandschaft und mit den Anforderungen der Branche Schritt halten.

Zusammenfassend lässt sich sagen, dass die Entscheidung für den Kauf von fertigen KI-Lösungen oder für die interne Entwicklung individueller KI-Lösungen von einem ausgewogenen Verhältnis mehrerer Faktoren abhängt. Der Kauf von KI-Lösungen bietet kosteneffiziente, schnell zu implementierende Lösungen, die gut unterstützt werden, was sie zu einer attraktiven Option macht, insbesondere für kleinere Unternehmen mit begrenzten Ressourcen. Der Nachteil ist jedoch ein potenzieller Mangel an Anpassungsmöglichkeiten, die möglicherweise nicht vollständig auf die individuellen Prozesse und Anforderungen eines Unternehmens abgestimmt sind.

Im Gegensatz dazu bietet die interne Entwicklung eigener KI-Lösungen ein hohes Maß an Individualisierung und Kontrolle, ideal für Unternehmen mit spezialisierten Prozessen und dem Wunsch nach innovativen, maßgeschneiderten KI-Anwendungen. Allerdings erfordert dieser Ansatz eine erhebliche Anfangsinvestition in Zeit und Ressourcen sowie Überlegungen zur laufenden Wartung und Skalierbarkeit.

Letztendlich sollte die Wahl auf eine sorgfältige Bewertung der spezifischen Bedürfnisse des Unternehmens, der Budgetbeschränkungen und der Fähigkeit zur Verwaltung der internen Entwicklung hinauslaufen. Unabhängig vom eingeschlagenen Weg besteht das übergeordnete Ziel darin, das transformative Potenzial der KI zu nutzen, um Produktionsprozesse zu optimieren, die Effizienz zu verbessern und die langfristige Wettbewerbsfähigkeit in der sich ständig weiterentwickelnden Industrielandschaft sicherzustellen. ^[64,65]



Literaturverzeichnis des Leitfadens

- [1] L. Heim und S. Gerth, „Künstliche Intelligenz: Chance oder Risiko für das Unternehmertum der Zukunft?“ in *Entrepreneurship der Zukunft*, L. Heim und S. Gerth, Hg., Wiesbaden: Springer Fachmedien Wiesbaden, 2023, S. 3-31, doi: 10.1007/978-3-658-42060-4_1.
- [2] P. Blies und C. Wasner, „KI erkennt nicht akzeptierbare Produktfehler“, *J Oberfl Techn*, Jg. 59, Nr. 3, S. 72-73, 2019, doi: 10.1007/s35144-019-0045-1.
- [3] A. Töpfer, P. Leffler, G. Brabänder und S. Silbermann, „Bedeutung und Ausgestaltung eines ganzheitlichen Qualitätsmanagements in der Künstlichen Intelligenz (KI)“ in *Forum Dienstleistungsmanagement, Künstliche Intelligenz im Dienstleistungsmanagement*, M. Bruhn und K. Hadwich, Hg., Wiesbaden: Springer Fachmedien Wiesbaden, 2021, S. 256-285.
- [4] T. Seyler, HOLO-KI: KI-basierte Qualitätskontrolle von Hochpräzisions-Drehteilen. Abschlussbericht, 2022. [Online]. Verfügbar unter: <https://publica.fraunhofer.de/handle/publica/416764>
- [5] N. Thielen, D. Werner, K. Schmidt, R. Seidel, A. Reinhardt und J. Franke, „A Machine Learning Based Approach to Detect False Calls in SMT Manufacturing“ in *2020 43rd International Spring Seminar on Electronics Technology (ISSE)*, Demanovska Valley, Slovakia, 2020, S. 1-6, doi: 10.1109/ISSE49702.2020.9121044.
- [6] B. Denkena, B. Bergmann, S. Reimer, A. Schmidt, T. Stiehl und M. Witt, „KI-gestützte Prozessüberwachung in der Zerspanung“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, Jg. 115, Nr. 5, S. 295-298, 2020, doi: 10.3139/104.112282.
- [7] T. Raffin, M. Baader, M. Masuch, M. Alikarrar und J. Franke, „Quality Monitoring of Hairpin Joints Using Optical Coherence Tomography and Machine Learning“ in *2024 1st International Conference on Production Technologies and Systems for E-Mobility (EPTS)*, 2024, S. 1-7.
- [8] S. Heißmeyer, D. Altmann und L. Overmeyer, „Lernfähige Instandhaltung“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, Jg. 105, Nr. 4, S. 333-338, 2010, doi: 10.3139/104.110294.
- [9] J. Wanner, L.-V. Herm, D. Hartel und C. Janiesch, „Verwendung binärer Datenwerte für eine KI-gestützte Instandhaltung 4.0“, *HMD*, Jg. 56, Nr. 6, S. 1268-1281, 2019, doi: 10.1365/s40702-019-00560-3.
- [10] M. Röglinger, T. Fehrer, T. Meyer-Hollatz und C. Luippold, *Prädiktive Prozessüberwachung in der Batterieproduktion*. [Online]. Verfügbar unter: <https://epub.uni-bayreuth.de/id/eprint/7519/3/Leitfaden%20KI%20ProBatt%20v1.1.pdf> (Zugriff am: 10. September 2024).
- [11] P. Wennker, *Künstliche Intelligenz in der Praxis: Anwendungen in Unternehmen und Branchen: KI wettbewerbs- und zukunftsorientiert einsetzen*. Wiesbaden, Germany, Heidelberg: Springer Gabler, 2020.
- [12] I. Seifert et al., „Potenziale der Künstlichen Intelligenz im produzierenden Gewerbe in Deutschland: Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi) im Rahmender Begleitforschung zum Technologieprogramm PAiCE -Plattformen | Additive Manufacturing | Imaging | Communication | Engineering“, Berlin, 2018.
- [13] S. Stowasser et al., *Einführung von KI-Systemen in Unternehmen: Gestaltungsansätze für das Change-Management*. [Online]. Verfügbar unter: https://www.isf-muenchen.de/wp-content/uploads/2020/11/AG2_Whitepaper_Change_Management.pdf (Zugriff am: 10. September 2024).
- [14] McKinsey, *Smartening up with Artificial Intelligence (AI) - What's in it for Germany and its Industrial Sector?* [Online]. Verfügbar unter: <https://www.mckinsey.com/industries/semiconduc-%20tors/our-insights/smartening-up-with-artificial-intelligence#/> (Zugriff am: 24. Juni 2024).
- [15] T. Herrmann und S. Pfeiffer, „Keeping the organization in the loop: a socio-technical extension of human-centered artificial intelligence“, *AI & Soc*, Jg. 38, Nr. 4, S. 1523-1542, 2023, doi: 10.1007/s00146-022-01391-5.
- [16] VDMA, *„Quick Guide. Machine Learning im Maschinen- und Anlagenbau“*, Frankfurt am Main, 2018.
- [17] S. Pfeiffer, „Kontext und KI: Zum Potenzial der Beschäftigten für Künstliche Intelligenz und Machine-Learning“, *HMD*, Jg. 57, Nr. 3, S. 465-479, 2020, doi: 10.1365/s40702-020-00609-8.
- [18] S. Pfeiffer, H. Lee und M. Held, „Doing Industry 4.0 - participatory design on the shop floor in the view of engineering employees“, *Cuad. Relac. Lab.*, Jg. 37, Nr. 2, S. 293-311, 2019, doi: 10.5209/crla.66039.
- [19] L. Pelzer, A. F. Posada-Moreno, K. Müller, C. Greb und C. Hopmann, „Process Parameter Prediction for Fused Deposition Modeling Using Invertible Neural Networks“, *Polymers*, Jg. 15, Nr. 8, S. 1884, 2023, doi: 10.3390/polym15081884.
- [20] R. H. Schmitt et al., „Improving Shop Floor-Near Production Management Through Data-Driven Insights“ in *Interdisciplinary Excellence Accelerator Series, Internet of Production*, C. Brecher et al., Hg., Cham: Springer International Publishing, 2023, S. 1-23, doi: 10.1007/978-3-030-98062-7_16-1.
- [21] K. Müller et al., „Entscheidungsunterstützung im Produktionsmanagement“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, Jg. 117, Nr. 3, S. 98-103, 2022, doi: 10.1515/zwf-2022-1015.
- [22] M. Hartwig, S.-C. Meyer, A. Tisch und S. Wischniewski, „Künstliche Intelligenz als Arbeitsmittel: Verbreitung und Zusammenhänge mit psychosozialen Arbeitsbedingungen“, *sis*, Nr. 2, 2023, doi: 10.37307/j.2199-7349.2023.02.08.
- [23] M. Dempsey, L. Geitner, A. Brennan und J. McAvoy, „A Review of the Success and Failure Factors for Change Management“, *IEEE Eng. Manag. Rev.*, Jg. 50, Nr. 1, S. 85-93, 2022, doi: 10.1109/EMR.2021.3130989.
- [24] A. Ullrich, M. Reißig, S. Niehoff und G. Beier, „Employee involvement and participation in digital transformation: a combined analysis of literature and practitioners' expertise“, *JOCM*, Jg. 36, Nr. 8, S. 29-48, 2023, doi: 10.1108/JOCM-10-2022-0302.
- [25] D. Greenbaum, „Expanding ELSI to all areas of innovative science and technology“, *Nat Biotechnol*, Jg. 33, Nr. 4, S. 425-426, 2015, doi: 10.1038/nbt.3193.
- [26] C. Brandl et al., „AMICAL: A Method Based on Risk Analysis to Integrate Responsible Research and Innovation into the Work of Research and Innovation Practitioners“, *Sci Eng Ethics*, Jg. 26, Nr. 2, S. 667-689, 2020, doi: 10.1007/s11948-019-00114-2.
- [27] E. Garcia, A. Costa, J. Palanca, A. Giret, V. Julian und V. Botti, „Requirements for an Intelligent Maintenance System for Industry 4.0“ in *Studies in Computational Intelligence, Service Oriented, Holonic and Multi-agent Manufacturing Systems for Industry of the Future*, T. Borangiu, D. Trentesaux, P. Leitão, A. Giret Boggino und V. Botti, Hg., Cham: Springer International Publishing, 2020, S. 340-351, doi: 10.1007/978-3-030-27477-1_26.
- [28] G. Satzger, L. Patrício, M. Zaki, N. Kühl und P. Hottum, Hg., *Exploring Service Science*. Cham: Springer International Publishing, 2018.
- [29] D. Schiff, B. Rakova, A. Ayesh, A. Fanti und M. Lennon, „Principles to Practices for Responsible AI: Closing the Gap“, 2020.
- [30] B. Rakova, J. Yang, H. Cramer und R. Chowdhury, „Where Responsible AI meets Reality“, *Proc. ACM Hum.-Comput. Interact.*, Jg. 5, CSCW1, S. 1-23, 2021, doi: 10.1145/3449081.
- [31] C. A. Escobar, M. E. McGovern und R. Morales-Menendez, „Correction to: Quality 4.0: a review of big data challenges in manufacturing“, *J Intell Manuf*, Jg. 32, Nr. 8, S. 2375, 2021, doi: 10.1007/s10845-021-01786-z.

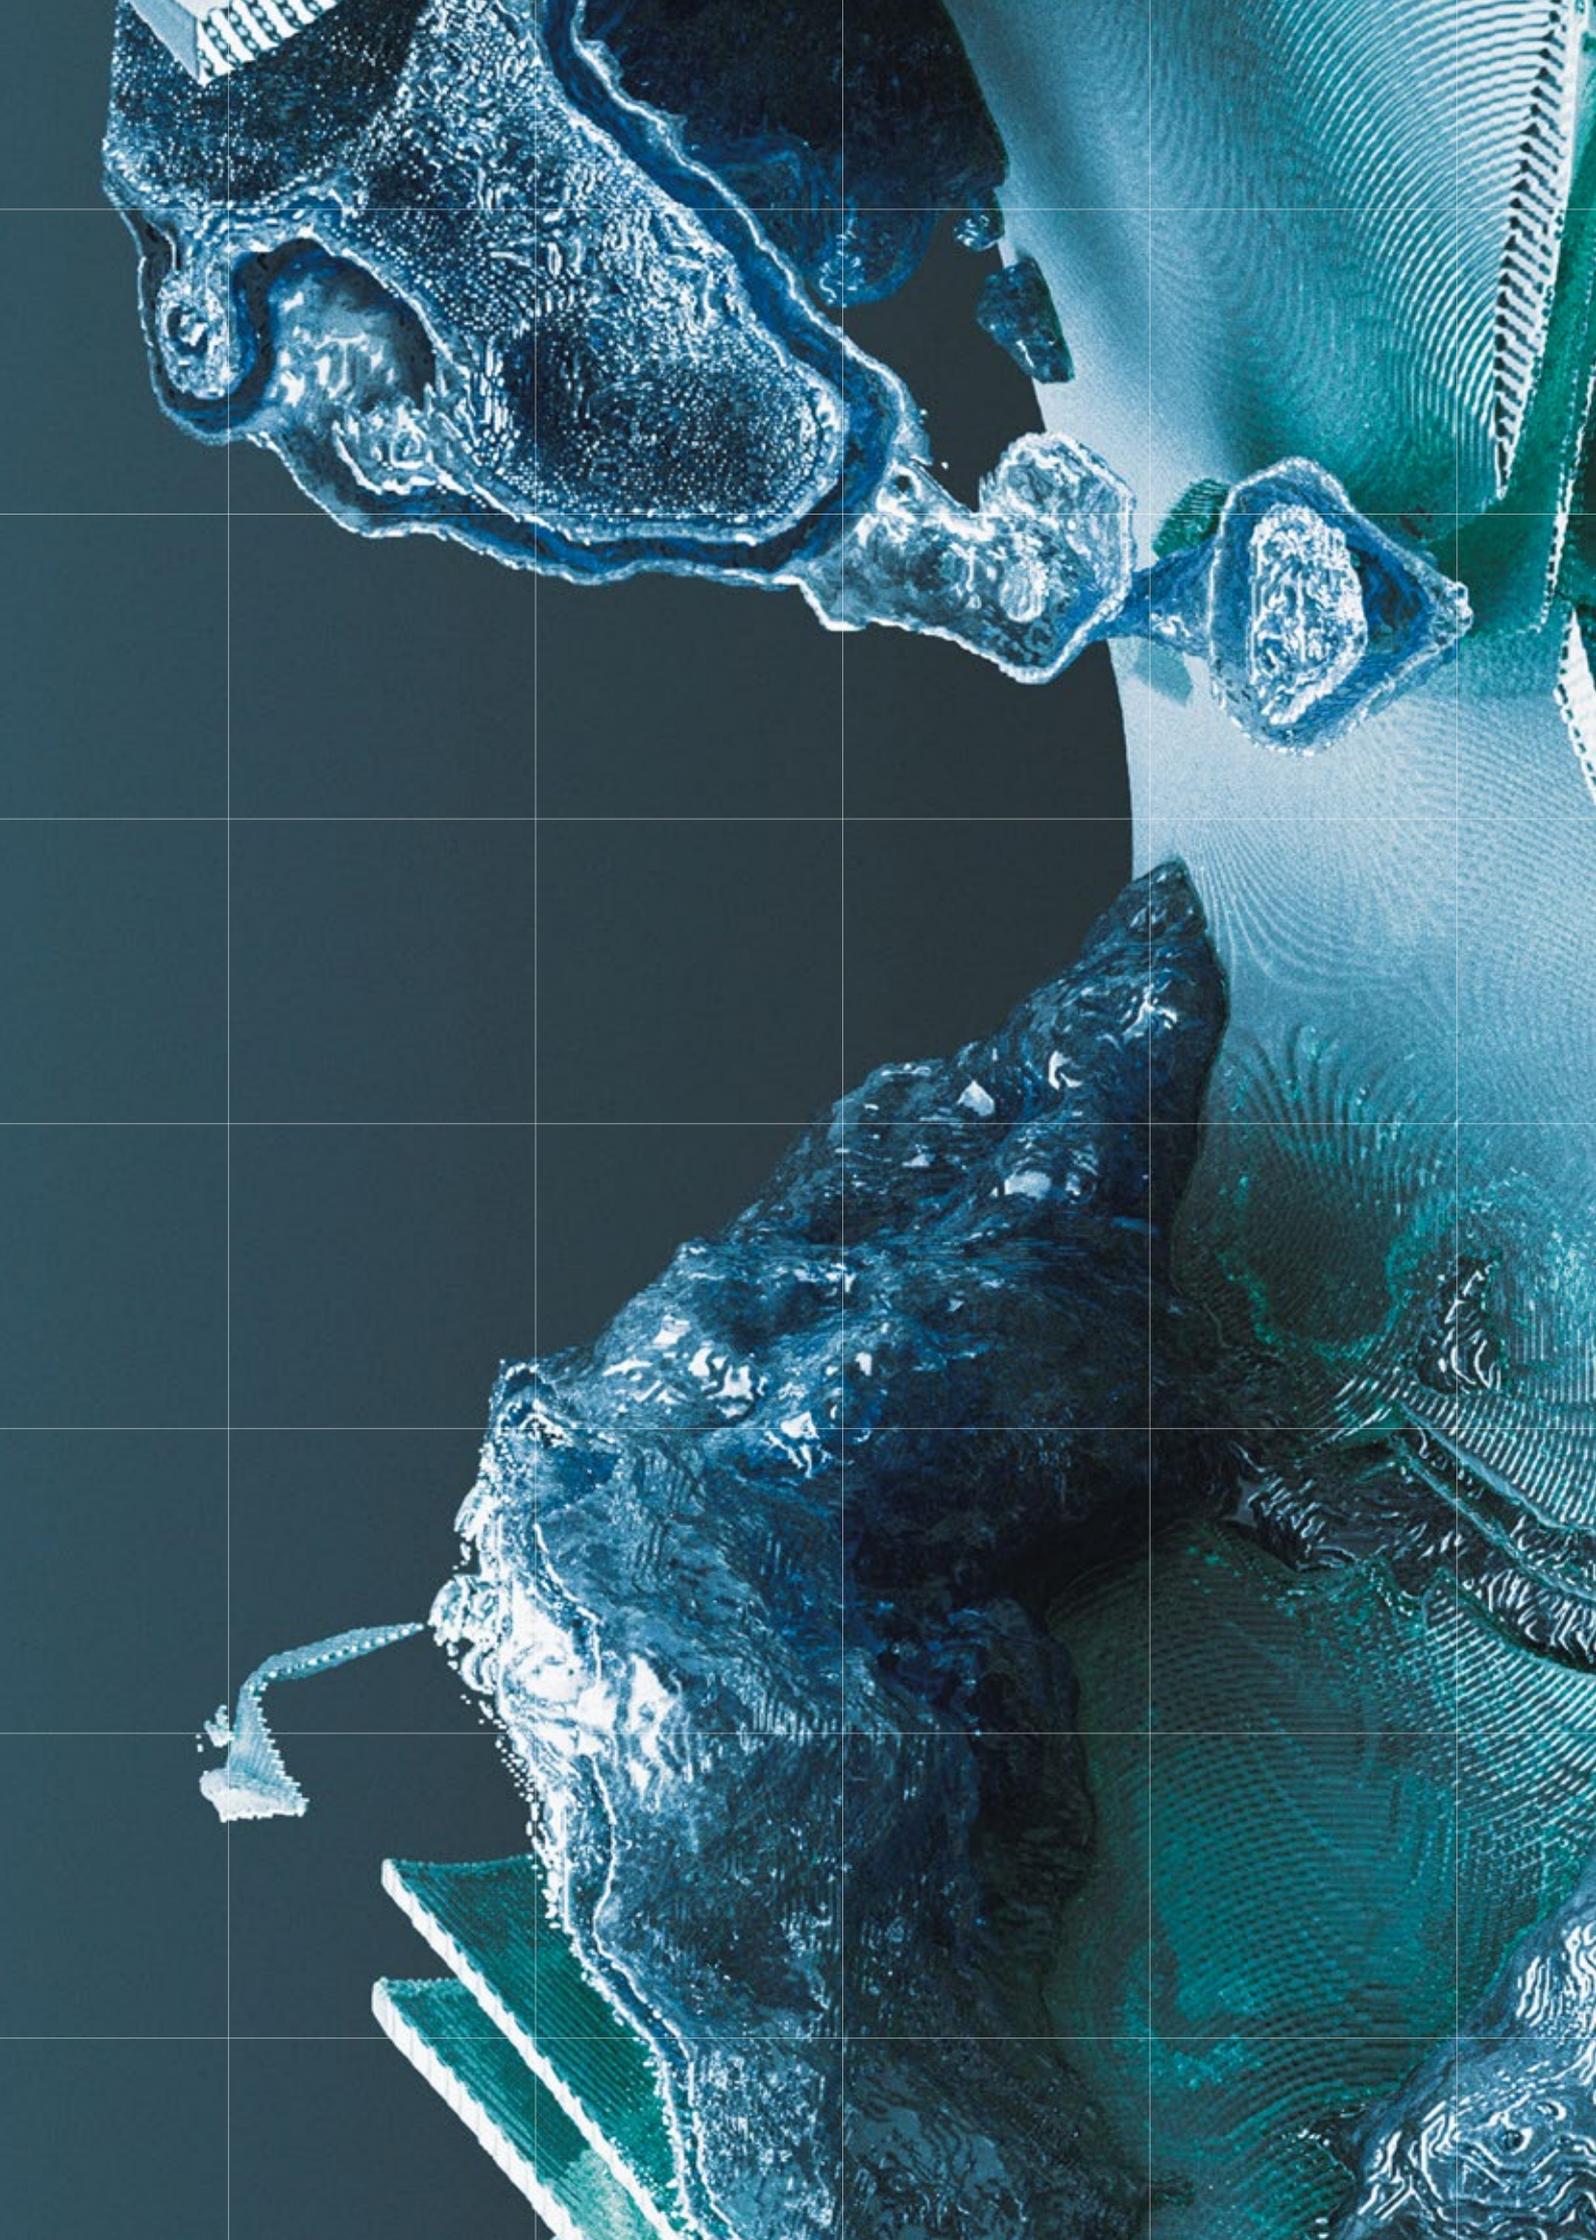


- [32] S. Meier, S. Klarmann, N. Thielen, C. Pfefferer, M. Kuhn und J. Franke, „A process model for systematically setting up the data basis for data-driven projects in manufacturing“, *Journal of Manufacturing Systems*, Jg. 71, S. 1-19, 2023, doi: 10.1016/j.jmsy.2023.08.024.
- [33] K. Maharana, S. Mondal und B. Nemade, „A review: Data pre-processing and data augmentation techniques“, *Global Transitions Proceedings*, Jg. 3, Nr. 1, S. 91-99, 2022, doi: 10.1016/j.gltp.2022.04.020.
- [34] A. Blázquez-García, A. Conde, U. Mori und J. A. Lozano, „A Review on Outlier/Anomaly Detection in Time Series Data“, *ACM Comput. Surv.*, Jg. 54, Nr. 3, S. 1-33, 2022, doi: 10.1145/3444690.
- [35] J. Summaira, X. Li, A. M. Shoib, S. Li und J. Abdul, „Recent advances and trends in multimodal deep learning: A review“, arXiv preprint arXiv:2105.11087, 2021.
- [36] M. Janssen, P. Brous, E. Estevez, L. S. Barbosa und T. Janowski, „Data governance: Organizing data for trustworthy Artificial Intelligence“, *Government information quarterly*, Jg. 37, Nr. 3, S. 101493, 2020.
- [37] L. P. English, *Improving data warehouse and business information quality: methods for reducing costs and increasing profits*. John Wiley & Sons, Inc, 1999.
- [38] K. Hildebrand, M. Gebauer und M. Mielke, *Daten- und Informationsqualität*. Wiesbaden: Springer Fachmedien Wiesbaden, 2021.
- [39] J. W. Burton, M.-K. Stein und T. B. Jensen, „A systematic review of algorithm aversion in augmented decision making“, *Behavioral Decision Making*, Jg. 33, Nr. 2, S. 220-239, 2020, doi: 10.1002/bdm.2155.
- [40] R. Parasuraman und V. Riley, „Humans and Automation: Use, Misuse, Disuse, Abuse“, *Hum Factors*, Jg. 39, Nr. 2, S. 230-253, 1997, doi: 10.1518/001872097778543886.
- [41] H. Mahmud, A. N. Islam, S. I. Ahmed und K. Smolander, „What influences algorithmic decision-making? A systematic literature review on algorithm aversion“, *Technological Forecasting and Social Change*, Jg. 175, S. 121390, 2022, doi: 10.1016/j.techfore.2021.121390.
- [42] E. Glikson und A. W. Woolley, „Human Trust in Artificial Intelligence: Review of Empirical Research“, *ANNALS*, Jg. 14, Nr. 2, S. 627-660, 2020, doi: 10.5465/annals.2018.0057.
- [43] F. D. Davis, „Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology“, *MIS Quarterly*, Jg. 13, Nr. 3, S. 319, 1989, doi: 10.2307/249008.
- [44] Venkatesh, Morris und Davis, „User Acceptance of Information Technology: Toward a Unified View“, *MIS Quarterly*, Jg. 27, Nr. 3, S. 425, 2003, doi: 10.2307/30036540.
- [45] B. J. Dietvorst, J. P. Simmons und C. Massey, „Overcoming Algorithm Aversion: People Will Use Imperfect Algorithms If They Can (Even Slightly) Modify Them“, *Management Science*, Jg. 64, Nr. 3, S. 1155-1170, 2018, doi: 10.1287/mnsc.2016.2643.
- [46] L. Zhang, I. Pentina und Y. Fan, „Who do you choose? Comparing perceptions of human vs robo-advisor in the context of financial services“, *JSM*, Jg. 35, Nr. 5, S. 634-646, 2021, doi: 10.1108/JSM-05-2020-0162.
- [47] Y. E. Bigman und K. Gray, „People are averse to machines making moral decisions“ (eng), *Cognition*, Jg. 181, S. 21-34, 2018, doi: 10.1016/j.cognition.2018.08.003.
- [48] K. Goodyear et al., „An fMRI and effective connectivity study investigating miss errors during advice utilization from human and machine agents“ (eng), *Social neuroscience*, Jg. 12, Nr. 5, S. 570-581, 2017, doi: 10.1080/17470919.2016.1205131.
- [49] P. Madhavan und D. A. Wiegmann, „Effects of information source, pedigree, and reliability on operator interaction with decision support systems“ (eng), *Human factors*, Jg. 49, Nr. 5, S. 773-785, 2007, doi: 10.1518/001872007X230154.
- [50] M. T. Dzindolet, L. G. Pierce, H. P. Beck und L. A. Dawe, „The perceived utility of human and automated aids in a visual detection task“ (eng), *Human factors*, Jg. 44, Nr. 1, S. 79-94, 2002, doi: 10.1518/0018720024494856.
- [51] C. Longoni und L. Cian, „Artificial Intelligence in Utilitarian vs. Hedonic Contexts: The “Word-of-Machine” Effect“, *Journal of Marketing*, Jg. 86, Nr. 1, S. 91-108, 2022, doi: 10.1177/0022242920957347.
- [52] E. Bogert, A. Schechter und R. T. Watson, „Humans rely more on algorithms than social influence as a task becomes more difficult“ (eng), *Scientific reports*, Jg. 11, Nr. 1, S. 8028, 2021, doi: 10.1038/s41598-021-87480-9.
- [53] A. Prahll und L. van Swol, „Understanding algorithm aversion: When is advice from automation discounted?“, *Journal of Forecasting*, Jg. 36, Nr. 6, S. 691-702, 2017, doi: 10.1002/for.2464.
- [54] D. Önkal, P. Goodwin, M. Thomson, S. Gönül und A. Pollock, „The relative influence of advice from human experts and statistical methods on forecast adjustments“, *Behavioral Decision Making*, Jg. 22, Nr. 4, S. 390-409, 2009, doi: 10.1002/bdm.637.
- [55] K. Kawaguchi, „When Will Workers Follow an Algorithm? A Field Experiment with a Retail Business“, *Management Science*, Jg. 67, Nr. 3, S. 1670-1695, 2021, doi: 10.1287/mnsc.2020.3599.
- [56] V. A. Shaffer, C. A. Probst, E. C. Merkle, H. R. Arkes und M. A. Medow, „Why do patients derogate physicians who use a computer-based diagnostic support system?“ (eng), *Medical decision making : an international journal of the Society for Medical Decision Making*, Jg. 33, Nr. 1, S. 108-118, 2013, doi: 10.1177/0272989X12453501.
- [57] W. M. Grove und P. E. Meehl, „Comparative efficiency of informal (subjective, impressionistic) and formal (mechanical, algorithmic) prediction procedures: The clinical-statistical controversy“, *Psychology, Public Policy, and Law*, Jg. 2, Nr. 2, S. 293-323, 1996, doi: 10.1037/1076-8971.2.2.293.
- [58] T. Araujo, N. Helberger, S. Kruikemeier und C. H. de Vreese, „In AI we trust? Perceptions about automated decision-making by artificial intelligence“, *AI & Soc*, Jg. 35, Nr. 3, S. 611-623, 2020, doi: 10.1007/s00146-019-00931-w.
- [59] C. J. Lourenço, B. G. Dellaert und B. Donkers, „Whose Algorithm Says So: The Relationships between Type of Firm, Perceptions of Trust and Expertise, and the Acceptance of Financial Robo-Advice“, *Journal of Interactive Marketing*, Jg. 49, Nr. 1, S. 107-124, 2020, doi: 10.1016/J.INTMAR.2019.10.003.
- [60] J. M. Logg, J. A. Minson und D. A. Moore, „Algorithm appreciation: People prefer algorithmic to human judgment“, *Organizational Behavior and Human Decision Processes*, Jg. 151, S. 90-103, 2019, doi: 10.1016/j.obhdp.2018.12.005.
- [61] N. Thurman, J. Moeller, N. Helberger und D. Trilling, „My Friends, Editors, Algorithms, and I“, *Digital Journalism*, Jg. 7, Nr. 4, S. 447-469, 2019, doi: 10.1080/21670811.2018.1493936.
- [62] C. Schröer, F. Kruse und J. M. Gómez, „A systematic literature review on applying CRISP-DM process model“, *Procedia Computer Science*, Jg. 181, S. 526-534, 2021.
- [63] Peter Chapman, „CRISP-DM 1.0: Step-by-step data mining guide“ in 2000.
- [64] Dario Stojicic, *Engine plant uses ABB's collaborative robot to improve quality and avoid stoppages*. [Online]. Verfügbar unter: <https://new.abb.com/news/detail/97634/cstmr-engine-plant-uses-abbs-collaborative-robot-to-improve-quality-and-avoid-stoppages> (Zugriff am: 18. September 2024).
- [65] Martin Bayer, *Wie sich Unternehmen in der Cloud neu erfinden*. [Online]. Verfügbar unter: <https://www.cio.de/a/wie-sich-unternehmen-in-der-cloud-neu-erfinden,3551973> (Zugriff am: 18. September 2024).

KI-LÖSUNGEN AUS DER PRAXIS

Die Produktion mit all ihren Herausforderungen ist ein sehr diverses und vor allem komplexes Feld. Anders als im privaten Gebrauch sind die Anforderungen an die KI-Lösungen in produzierenden Unternehmen in der Regel viel höher gesetzt. Darüber hinaus gibt es nicht die eine Lösung für alle Probleme, sondern vielmehr einen bunten Blumenstrauß an Lösungen.

Im folgenden Teil dieses Projektatlas werden viele „KI-Lösungen aus der Praxis“ als ein Ausschnitt aus diesem Blumenstrauß präsentiert. Mit „Lösungen“ sind auch hier nicht nur die KI-Algorithmen gemeint, sondern auch die vielen Bausteine, die KI erst möglich machen.



KI-LÖSUNGEN AUS DER PRAXIS

50-71

72-101

102-141

142-189

190-233

234-265

STRATEGIE

DIGITALISIERUNG

DATEN

KI-METHODEN

MENSCH UND KI

PROJEKTSTECKBRIEFE



WEGWEISER

Wie jedes andere Werkzeug wird KI nur dann in der Produktion eingesetzt, wenn Sie einen Mehrwert stiftet. Mehrwerte können durch Steigerung der Maschinenverfügbarkeit, der Produktivität oder Qualität erwirtschaftet werden. Weiterhin können beispielsweise der Erhalt von Expertenwissen oder eine höhere Flexibilität Gründe sein, um KI einzusetzen. Das unternehmensinterne Know-how und somit die Daten des Unternehmens sollten dabei stets geschützt werden. Auch die Gesetzgeber streben aufgrund des disruptiven Charakters eine Regulierung des KI-Einsatzes an. All diese Aspekte für einen wirtschaftlichen und strategischen Einsatz von KI werden in diesem Kapitel beleuchtet. Außerdem erwarten Sie Interviews und Artikel zu den Themen Regulierung von KI, Datensouveränität, Wirtschaftlichkeit und Lessons-Learned unserer Expertinnen und Experten.

*Verantwortlich für dieses Kapitel:
Lukas Gründel, Werkzeugmaschinenlabor WZL der RWTH Aachen University*



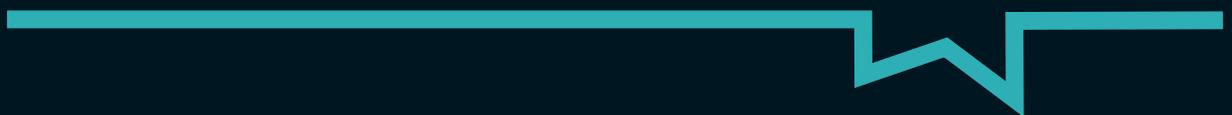
WIRTS UND ST



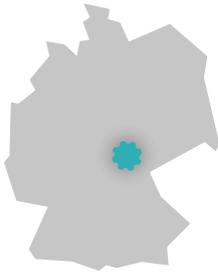
An aerial photograph of a forest, overlaid with a white grid. A white silhouette of a bear is superimposed on the forest, appearing to walk across it. The text 'CHAFTLICHER', 'STRATEGISCHER', and 'EINSATZ' is written in large, white, bold, sans-serif capital letters across the bottom of the image, with horizontal lines separating the words.

CHAFTLICHER
STRATEGISCHER
EINSATZ

EXPERTINNEN UND EXPERTEN AUS INDUSTRIE, FACHVERBÄNDEN UND DER FORSCHUNG BESCHREIBEN DIE HERAUSFORDERUNGEN UND MÖGLICHE LÖSUNGSWEGE, KI SOWOHL STRATEGISCH EINZUSETZEN ALS AUCH WIRTSCHAFTLICH RICHTIG ZU BEWERTEN.



- 
- 54** Motivation zur Implementierung von Künstlicher Intelligenz: Herausforderungen und Lösungsansätze für kleine und mittlere Unternehmen (KMU)
- 60** Interview mit Polina Khubbeeva, Bundesverband der deutschen Industrie
- 62** Interview mit Dr. Christoph Kelzenberg, Phoenix Contact
- 66** Wirtschaftlichkeitsbewertung von KI-Projekten: Ein Beispiel für erklärbare KI zur Rüstzeitoptimierung in der CNC-Werkzeugherstellung
MetaLearn



ProKI Ilmenau

MOTIVATION ZUR IMPLEMENTIERUNG VON KÜNSTLICHER INTELLIGENZ

HERAUSFORDERUNGEN UND LÖSUNGSANSÄTZE FÜR KLEINE UND MITTLERE UNTERNEHMEN (KMU)

Sebastian Gerth (Fachgebiet Fertigungstechnik an der Fakultät für Maschinenbau an der Technischen Universität Ilmenau)

Abstract

Der vorliegende Beitrag subsummiert unterschiedliche Herausforderungen von KMU bei der Einführung von Künstlicher Intelligenz (KI) und bietet Motivation durch Lösungsansätze für kleinere und mittlere Unternehmen (KMU). Betrachtet werden die Einsatzmöglichkeiten von KI, Aspekte zur Einschätzung des potentiellen Kosten-Nutzen-Verhältnisses von KI-Projekten sowie das Zusammenspiel von Mensch und KI im Unternehmen. Es wird anhand von Empfehlungen zu praktischen Vorgehensweisen argumentiert, dass die Hürden der KI-Implementierung oftmals höher angenommen werden als sie tatsächlich sind. Dies liegt zum einen an oftmals überschätzten technischen, wirtschaftlichen und sozialen Hemmnissen. Zum anderen zeigt sich jedoch ebenso, dass KMU durch zahlreiche Anlaufstellen bei Fragen zu KI vielfältig unterstützt werden.

1. Einführung: Künstliche Intelligenz als Innovationstreiber – Motivation auch in der Praxis?

Künstliche Intelligenz (KI) wird nicht erst seit dem Erfolg von ChatGPT des US-amerikanischen Softwareunternehmens OpenAI zu Beginn des Jahres 2023 für den Einsatz in der Produktion erforscht und gefördert,

sondern dieser Forschungsbereich kann mittlerweile auf eine lange Tradition seit den 1970er Jahren zurückblicken ^[1, S. 4ff.]. Aktuell wird im Produktionsbereich insbesondere an KI-basierten Lösungen in der Qualitätskontrolle ^[2-4], der Prozessüberwachung ^[5] und der (prädiktiven) Instandhaltung (vgl. z.B. ^[6-8]) in der Wirtschaft und Wissenschaft gearbeitet (ein breiteres Feld zeigen z.B. ^[9] oder ^[10]). Auch innovative Geschäftsmodelle sind Teil der Forschung (vgl. etwa ^[11-13]). Dabei werden, auch im Zuge diverser Transfermaßnahmen zwischen wirtschaftlichen und wissenschaftlichen Akteuren, aktuelle Herausforderungen insbesondere für die Wirtschaft - z.B. der Fachkräftemangel, Lieferkettenschwierigkeiten oder auch steigende Energiepreise - neben weiteren Handlungsoptionen aus Politik und Gesellschaft adressiert. KI scheint in der Lage zu sein, mindestens Lösungsansätze für drängende Probleme finden oder diese gar umsetzen zu können. Dabei muss berücksichtigt werden, dass KI selbst ein Treiber der Innovation und insbesondere der Digitalisierung darstellt - denn um KI einführen und nutzen zu können, müssen häufig bislang nicht getätigte Digitalisierungsmaßnahmen zur Datenerhebung in die Tat umgesetzt werden (vgl. etwa ^[14]). Hierfür gibt es unterschiedliche Herangehensweisen,



die sich in einem innovativen Forschungsfeld - wie KI es in der aktuellen Situation und im Hinblick auf die Schnelligkeit der Fortschritte zweifelsfrei ist - stets im Spannungsverhältnis zwischen bewährten und noch zu erforschenden Ansätzen bewegen. Es bleibt aber bereits heute festzuhalten, dass konventionelle Ansätze, wie z.B. die Produktion oder Qualitätsprüfung durch rein standardisiert(-lineare) Prozesse im Labormaßstab bereits oft von KI bei der spezifischen Zielerreichung durch nicht-standardisierte Methoden resp. Modellanwendungen durch spezifische KI-Architekturen übertroffen werden können ^[15]. Dies erfolgt beispielsweise durch das Erkennen neuer Muster oder Zusammenhänge in den zugrunde liegenden Daten - hierzu sind traditionell gewachsene Prozesse zumeist nicht in der Lage. Der Schritt zur tatsächlichen Umsetzung entsprechender KI-Technologien in der produzierenden Industrie ist bisher allerdings v.a. nur in Einzelfällen erfolgreich und im Mittelstand daher wenig verbreitet ^[16-19]; ferner ^[20-22] mit internationalem Bezug. Dies unterstreicht einerseits die anhaltende Innovation, die von der Einführung von KI in bestehenden Unternehmensprozesse ausgeht ^[23, S. 131ff.]. Andererseits zeigt es gleichzeitig, dass in der Wissenschaft bereits zahlreiche Lösungen erforscht worden sind, aber der Transfer in die Unternehmenslandschaft nach wie vor ein Desiderat darstellt.

Der vorliegende Beitrag zeigt wesentliche - mitunter verständlicher Weise die KI-Verantwortlichen in KMU demotivierende - Probleme auf, vor denen Unternehmen bei bevorstehenden KI-Projekten stehen und bietet gleichzeitig Lösungsansätze, die trotz der Schwierigkeiten zur Motivation und damit Umsetzung einer KI-Implementierung in KMU beitragen. So lassen sich insbesondere die nachfolgend genannten drei übergeordneten Problematiken und Lösungsansätze identifizieren, die sich je nach Unternehmensgröße, den wirtschaftlichen Rahmenbedingungen und dem Reifegrad der spezifischen digitalen Transformation von Unternehmen zu Unternehmen unterscheiden können.

2. Problemstellungen und Lösungsansätze

Die nachfolgend diskutierten Punkte bieten ein Rahmenkonstrukt, welches im Wesentlichen bei den meisten KMU eine Rolle spielen dürfte, sobald es um die Etablierung von KI-Technologien geht (vgl. auch den Überblick in ^[24, 25] mit internationalem Bezug).

1. Einsatzmöglichkeiten von KI im Unternehmen

Problemstellung: Voraussetzung für eine gelingende Einführung von KI ist eine Basisdigitalisierung im Unternehmen, welche mit der Erhebung von Daten einhergeht. Ohne Daten ist jede weitere Überlegung zur KI-Implementierung obsolet ^[26]. Die Einsatzmöglichkeiten von KI richten sich dementsprechend nach der Verfügbarkeit von Daten und ihrer Menge sowie Qualität, d.h. ihrer für ein zielführendes Modelltraining im Zuge des Machine Learnings sinnvollen Strukturierung und ausreichenden Quantifizierung ^[27]. Es kann mitunter vorkommen, dass im Unternehmen zum einen ablaufende Prozesse und zum anderen die Quelle und Art der Datengenerierung sowie ihre Aufbereitung im Sinne der gespeicherten Informationen und den hierin abgebildeten Informationsbeziehungen teilweise oder gar gänzlich unbekannt sind - diese jedoch sind die ‚Kompassnadel‘ für KI-Projekte, denn hier finden sich häufig die zu lösenden Probleme oder die zu optimierenden Aspekte. Innerhalb von KMU sind die Einsatzmöglichkeiten von KI daher häufig unbekannt. Dies liegt einerseits am vorab beschriebenen, mangelnden Wissen über die eigenen Daten, aber andererseits auch am fehlenden Know-how über die Chancen und Grenzen für die Voraussetzungen von KI-Technologien und ihre praktische Nutzung.

Lösungsansatz zur Motivation: Es empfiehlt sich, in einem ersten Schritt maßgebliche Probleme im Unternehmen in einem für alle Mitarbeitenden offenen Verfahren zu identifizieren. Dabei sollte berücksichtigt werden, dass ihre Lösung nicht zwingend KI-Technologien voraussetzt. Häufig gelangen auch andere Optionen zur Anwendung, etwa aus dem mittlerweile in zahlreichen Unternehmen bewährten Automatisierungsbereich. Gleichzeitig sollte im Unternehmen



eruiert werden, welche Daten in welcher Form zur Problemlösung vorliegen (Sensorik, Software etc.). Darüber hinaus empfiehlt sich die Überlegung, wie notwendige Daten - sofern diese noch nicht vorhanden sind - zukünftig erhoben und aufbereitet werden könnten, um der Lösungsfindung näher zu kommen (vgl. zu sog. ganzheitlichen Datenmodellen in Produktionssystemen auch ^[28]). Für einen solchen Schritt im Bereich der digitalen Transformation kann z.B. von einem Data Scientist eine übersichtliche Systematik angefertigt werden, anhand derer KI-Experten das anschließende Vorgehen abschätzen können (mögliche Einsatzszenarien von KI verdeutlichen u.a. ^[29] oder ^[30]). Hierfür ist die Formulierung einer expliziten KI-Strategie unabdingbar, die über das einzelne KI-Projekt hinausgeht.

2. Einschätzung des Potenzial-Ressourcen-Verhältnisses von KI-Projekten

Problemstellung: Trotz der umfangreichen Forschung und einer Vielzahl von auf diversen Plattformen zur Verfügung stehenden Tutorials und Schulungen in vielen unterschiedlichen Domänen, fällt KI-Verantwortlichen in KMU häufig die Abschätzung schwer, welche Ressourcen für welchen potenziellen Mehrwert bei der Umsetzung eines KI-Projektes aufgewendet werden müssen. So ist mitunter unklar, welches Wissen für die erfolgreiche Durchführung des KI-Projektes aufgebaut werden muss, ob dieses intern im Unternehmen zur Verfügung steht oder ob es durch externe Dritte bereitgestellt werden muss. Es ist für KI-Projektmanager häufig auch schwer abzuschätzen, welche finanziellen Mittel für die Umsetzung notwendig sind, wie die Organisation und Arbeit angepasst werden kann und welche operativen Schritte letzten Endes für den Einsatz von KI durchzuführen sind (vgl. hierzu z.B. ^[17, S. 37-47] und ^[31]). Darüber hinaus bleiben häufig Fragen zum Datenschutz und der Datensicherheit unbeantwortet - dies ist aber gerade deshalb von Bedeutung, da bei KI häufig mit großen Datenmengen von wichtigen Datenquellen operiert wird. Unsicherheit besteht mitunter auch darin, durch welche geeigneten Schnittstellen KI-Lösungen in bestehenden (IT-)Infrastrukturen eingebettet werden können. Auch rechtliche Regulie-

rungsfragen insbesondere vor dem Hintergrund von Haftungsansprüchen kommen auf, wenngleich diesbezüglich der jüngst in Kraft getretene EU AI Act bereits für mehr Klarheit und Vertrauen sorgen dürfte (vgl. hierzu z.B. ^[32]). Insbesondere ist den Verantwortlichen in einem KMU erfahrungsgemäß das exakte Outcome einer KI-Implementierung und damit der Break-Even-Point resp. die Gewinnschwelle der Investition und die zu erwartenden Optimierungskennzahlen in Bezug z.B. auf Qualität oder Umsatz unklar.

Lösungsansatz zur Motivation: Je nach Einsatzgebiet lässt sich ein Potenzial-Ressourcen-Verhältnis mehr oder weniger quantitativ abbilden. Im produzierenden Gewerbe etwa dürfte dies relativ einfach sein: Bei der Planung, der Inbetriebnahme und dem laufenden Betrieb von Produktionsstraßen liegen nahezu ausschließlich quantitative Größen zugrunde, etwa im Hinblick auf die Kosten von Maschinen(-laufzeiten), produzierten Stückzahlen je Zeiteinheit, standardisierten Qualitätsparametern, Wartungsintervallen usw. Entsprechende technische und betriebswirtschaftliche Kennzahlen sind daher ein erster Anhaltspunkt - zum einen retro- und zum anderen prospektiv. Dies gilt grundsätzlich für jedes KI-Projekt bei der Planung, denn die entstehenden Kosten sind durch entsprechende Dienstleister abschätzbar. Seriöse Anbieter sollte unter Berücksichtigung fundierter Key Performance Indicators (KPIs) auch eine Prognose über den zahlenmäßig zu erwartenden, potenziellen Mehrwert liefern können. Dieser bleibt zwar letztlich eine Schätzung, denn unvorhergesehene Entwicklungen sind unvermeidbar. Zukunftsorientiert jedoch kann eine fundierte, zahlenmäßig basierte Analyse durchaus bei der Entscheidungsfindung helfen.

Es gibt jedoch auch KI-Projekte, bei denen Kennzahlen weniger stark zur o.g. Verhältniseinschätzung beitragen können. Dies ist etwa dann der Fall, wenn KI im generativen Bereich (etwa im Marketing oder Service), bei der Transaktionsverwaltung (etwa in der Buchhaltung oder Logistik) oder dem Dokumentenmanagement bzw. der entsprechenden Bewertung (etwa in der Verwaltung oder im Personalwesen) eingesetzt



werden soll. Hier ist es nahezu unmöglich, das Optimierungspotenzial durch KI seriös zu beziffern. Es ist dabei nicht unüblich, die eingesetzten Mittel als eine Art ungewisse Zukunftsinvestition zu riskieren und möglichst positive Spillover-Effekte auch auf andere Geschäftsbereich zu provozieren. Der Maßstab für entsprechende Projekte kann daher nicht quantitativ sein, sondern ist qualitativ geprägt: Trägt die KI-Lösung maßgeblich zur Verbesserung der Arbeitssituation meiner Mitarbeitenden bei? Kann durch KI der Service im Sinne meiner Kunden optimiert werden? Hier sind entsprechende Maßstäbe - je nach Einsatzszenario - anzusetzen. Aus Vergleichbarkeitsgründen zwischen Invest (KI-Projekt, z.B. in Euro) und Outcome (z.B. Zufriedenheit) kann letztgenanntes auch in standardisierte Befragungen der Zielgruppe anhand geeigneter Itembatterien überführt und entsprechend z.B. anhand von Mittelwerten ebenso quantitativ bewertet werden. Zwar sind hier die bekannten Problematiken von Befragungen zu beachten (z.B. Antworten sozialer Erwünschtheit), aber es können bei ausreichender Befragtenanzahl zur Absicherung statistischer Effekte KPIs von Invest-Outcome bzw. Soll-Ist einander gegenüber gestellt werden. Kleinere Pilotprojekte können darüber hinaus dabei helfen, das Verhältnis zwischen Aufwand und Nutzen im kleinen Rahmen abzustecken.

3. Zusammenspiel von Mensch und KI

Problemstellung: Die obigen Ausführungen zeigen bereits, dass KI häufig eine Schnittstellentechnologie zwischen Mensch und Maschine ist. In der Kooperation von Mensch und KI zeigen sich besondere Herausforderungen, die für den erfolgreichen Einsatz von KI von hochrelevanter Bedeutung sind. Auf der einen (unternehmensinternen) Seite können Mitarbeitende in einer KI etwa Konkurrenz um den eigenen Arbeitsplatz sehen, was die Akzeptanz der KI im Unternehmen senken kann. Möglich ist auch, dass die Mitarbeitenden die Technologie schlicht nicht verstehen oder ihr nicht vertrauen und ggf. die Reichweite bestimmter Interaktionen nicht überblicken. Im schlimmsten Fall würde eine Technologie durch ein großes Investitionsvolumen - v.a. in Soft- und Hardware sowie deren

Programmierung und Einrichtung - implementiert, aber die Mitarbeitenden würden eine Nutzung bzw. Zusammenarbeit ablehnen oder gar sabotieren. Dann würde nicht nur die Investition obsolet, sondern auch die Identifikation mit dem Unternehmen durch die Mitarbeitenden und ihre Motivation für weitere Tätigkeiten im Sinne des Arbeitgebers maßgeblich beeinträchtigt. Das wäre eine doppelte Schwächung des Unternehmens.

Auf der anderen (unternehmensexternen) Seite müsste ebenso die Akzeptanz von KI z.B. durch Kunden eruiert werden: Sind diese bereit, mit Chatbots zu interagieren anstatt mit Menschen? Sind Werbetexte - etwa für die eigenen Produkte oder aber auch für das eigene Unternehmen im Zuge eines Employer Brandings bei der Personalgewinnung bzw. -sicherung - durch KI-generierte Inhalte wie Bilder oder Texte wirklich überzeugend? Ist eine KI mindestens genauso vertrauenswürdig wie ein Mensch? Trifft eine KI ethisch vertretbare Entscheidungen? Diese und weitere Fragen lassen mitunter Zweifel aufkommen, ob und welcher Mehrwert durch das Zusammenspiel von KI und Menschen geschaffen wird.

Lösungsansatz zur Motivation: Zunächst sei auch an dieser Stelle auf den Lösungsansatz von Punkt (1) verwiesen: Die Menschen - egal, ob Mitarbeitende, Kunden oder am Wertschöpfungsprozess beteiligte Dritte - müssen von Beginn an im Rahmen eines fundierten Change Managements in das KI-Projekt involviert und der zu erwartende Mehrwert klar kommuniziert werden^[33]. Dies gilt insbesondere für jenen Personengruppen, die mit dem KI-System interagieren müssen (vgl. zu menschenzentrierten KI-Anwendungen in der Produktion z.B. Pokorni, Braun & Knecht 2021), denn die Einführung von KI bedeutet letztlich auch einen gewissen Kulturwandel im Unternehmen. Den Betroffenen muss klar sein, dass die KI keine Konkurrenz, sondern eine Unterstützung darstellt. Sobald eine KI von den Mitarbeitenden identifizierte Probleme löst und somit den Arbeitsalltag erleichtert, ohne dass die Angst des Arbeitsplatzverlustes begründet ist, dürfte die KI auch als ‚Kollege‘ akzeptiert werden (vgl. den



Beitrag von Carrara et al. in diesem Band). Dieser Effekt dürfte sich verstärken, wenn die Mitarbeitenden einen zusätzlichen Mehrwert durch den Einsatz von KI erfahren (vgl. zur Überführung von KI-Widerständen in eine produktive Dynamik ^[34]). Dies kann z.B. eine geringere Arbeitsbelastung oder auch ein Zeitgewinn für andere Aufgaben oder - je nach Führungsstil der Vorgesetzten bzw. Unternehmenskultur - Freizeit sein. Hierfür sollte es ein dezidiertes Kommunikationskonzept als Teil des KI-Projektmanagements geben, anhand dessen die technischen und wirtschaftlichen Aspekte eines KI-Projektes auch mit sozialen Interessen in Einklang gebracht werden. Ein solches Konzept erhält nicht nur Aspekte, um die KI-Lösung transparent darzustellen, sondern z.B. auch Schulungen, ethische Richtlinien für den Einsatz der KI, Q&A-Runden zwischen Mitarbeitenden und KI-Projektverantwortlichen sowie die Eruiierung weiterer Aspekte, bei denen die KI die Mitarbeitenden unterstützen kann. Dabei gilt zu beachten, dass KI auch den Fachkräftemangel abzufedern vermag, indem sie entweder direkt passende Aufgaben übernimmt oder indem KI-Projekte motivierte Menschen für das eigene Unternehmen indirekt begeistern - so können neue Mitarbeitende durch KI gewonnen oder bereits gebundenen Teammitglieder im Unternehmen gehalten werden.

3. Fazit

Der Beitrag verdeutlicht überblickshaft häufig auftretende Schwierigkeiten und Hemmnisse bei der KI-Implementierung (vgl. ferner die vier typischen Anfangshürden bei KI-Projekten ^[35]). Obwohl diese mitunter auf den ersten Blick verständlicherweise demotivierend wirken können, zeigen zum einen z.B. Seifert et al. in ^[36]. Auch die o.g. gebotenen Lösungsansätze für etwaige Hemmnisse verdeutlichen v.a. motivatorische Komponenten: KI ist letztlich kein ‚Hexenwerk‘. So verwundert es nicht, dass z.B. Ulrich & Bachlechner in ^[37] wirtschaftliche Bewertungen von KI im Praxiseinsatz inkl. Handlungsempfehlungen vorlegen. Wangermann verdeutlicht in ^[38] umfangreich die Rahmenbedingungen für den Transfer von KI-Anwendungen in KMU und Haag & Pyschny stellen in ^[39]

einen nutzbringenden Bewertungsrahmen vor, der bei der KI-Einführung unterstützen kann. Die Business School Berlin (2021) stellt unter Zusammenarbeit zahlreicher ein ‚KI-Kochbuch‘ vor, welches ‚Rezepte‘ für den Einsatz Künstlicher Intelligenz in Unternehmen‘ bereitstellt. Harlacher et al. formulieren in ^[31] darüber hinaus eigene Roadmaps für den Weg zu KI-Lösungen und Haarmeier beschreibt in ^[17, S. 37-47] daran angelehnt ein grundsätzliches Vorgehen und gibt eine Übersicht über verfügbare Anwendungen ^[17, S. 27-36]. KMU werden also nicht allein gelassen auf ihrem Weg zu (und ihrer Motivation für) KI-Innovationen. Denkbar sind auch Verbundprojekte zwischen Universitäten und Unternehmen oder KMU untereinander (vgl. etwa ^[40]). Darüber hinaus gibt es zahlreiche Unterstützungsangebote auf dem Markt von Expert:innen unterschiedlichster Institutionen, von denen KMU unbedingt Gebrauch machen sollten - eine Vielzahl an Ansprechpartnern finden sich in diesem Beitrag und dem gesamten, vorliegenden Werk. Dies ist v.a. deshalb wichtig, um die eingangs getätigte Problematik in Zukunft im Sinne des Innovationstreibers KI in Deutschland aufzulösen: Die derzeit noch geringe Verbreitung von KI in KMU.

Literatur

- [1] L. Heim und S. Gerth, „Künstliche Intelligenz: Chance oder Risiko für das Unternehmertum der Zukunft?“, in Entrepreneurship der Zukunft, L. Heim und S. Gerth, Hg., Wiesbaden: Springer Fachmedien Wiesbaden, 2023, S. 3-31.
- [2] T. Seyler, HOLO-KI: KI-basierte Qualitätskontrolle von Hochpräzisions-Drehteilen. Abschlussbericht, 2022. [Online]. Verfügbar unter: <https://publica.fraunhofer.de/handle/publica/416764>
- [3] A. Töpfer, P. Leffler, G. Brabänder und S. Silbermann, „Bedeutung und Ausgestaltung eines ganzheitlichen Qualitätsmanagements in der Künstlichen Intelligenz (KI),“ in Künstliche Intelligenz im Dienstleistungsmanagement (Forum Dienstleistungsmanagement), M. Bruhn und K. Hadwich, Hg., Wiesbaden: Springer Fachmedien Wiesbaden, 2021, S. 256-285.
- [4] P. Blies und C. Wasner, „KI erkennt nicht akzeptierbare Produktfehler,“ J Oberfl Techn, Jg. 59, Nr. 3, S. 72-73, 2019, doi: 10.1007/s35144-019-0045-1.
- [5] B. Denkena, B. Bergmann, S. Reimer, A. Schmidt, T. Stiehl und M. Witt, „KI-gestützte Prozessüberwachung in der Zerspanung,“ Zeitschrift für wirtschaftlichen Fabrikbetrieb, Jg. 115, Nr. 5, S. 295-298, 2020, doi: 10.3139/104.112282.
- [6] M. Röglinger, T. Fehrer, T. Meyer-Hollatz und C. Luippold, „Prädikative Prozessüberwachung in der Batterieproduktion.“ Zugriff am: 10. September 2024. [Online.] Verfügbar: <https://epub.uni-bayreuth.de/id/eprint/7519/3/Leitfaden%20KI%20ProBatt%20v1.1.pdf>
- [7] J. Wanner, L.-V. Herm, D. Hartel und C. Janiesch, „Verwendung binärer Datenwerte für eine KI-gestützte Instandhaltung 4.0,“ HMD, Jg. 56, Nr. 6, S. 1268-1281, 2019, doi: 10.1365/s40702-019-00560-3.
- [8] S. Heißmeyer, D. Altmann und L. Overmeyer, „Lernfähige Instandhaltung,“ Zeitschrift für wirtschaftlichen Fabrikbetrieb, Jg. 105, Nr. 4, S. 333-338, 2010, doi: 10.3139/104.110294.



- [9] M. Öfele, C. Hartmann, S. Sommer, F. Kerber und S. Braunreuther, „8 KI in der Produktion,“ in *Künstliche Intelligenz und menschliche Gesellschaft*, L. Kovács, Hg., De Gruyter, 2023, S. 105-120.
- [10] A. Mockenhaupt, *Digitalisierung und Künstliche Intelligenz in der Produktion: Grundlagen und Anwendung (Lehrbuch)*, Wiesbaden, Heidelberg: Springer Vieweg, 2021.
- [11] J. Winter, „Mit Daten und Künstlicher Intelligenz zu digitalen Geschäftsmodellen - Praxisbeispiele aus Produktion, Logistik und Gesundheitswirtschaft,“ in *Künstliche Intelligenz im Dienstleistungsmanagement (Forum Dienstleistungsmanagement)*, M. Bruhn und K. Hadwich, Hg., Wiesbaden: Springer Fachmedien Wiesbaden, 2021, S. 76-97.
- [12] C. Moll und C. Lerch, „KI-basierte Geschäftsmodelle im verarbeitenden Gewerbe - Anwendungspotenziale und Gestaltungsmöglichkeiten,“ in *Künstliche Intelligenz im Dienstleistungsmanagement (Forum Dienstleistungsmanagement)*, M. Bruhn und K. Hadwich, Hg., Wiesbaden: Springer Fachmedien Wiesbaden, 2021, S. 98-119.
- [13] P. Knapp und C. Wagner, „Künstliche Intelligenz schafft neue Geschäftsmodelle im Mittelstand,“ in *Künstliche Intelligenz*, P. Buxmann und H. Schmidt, Hg., Berlin, Heidelberg: Springer Berlin Heidelberg, 2019, S. 161-172.
- [14] Safar und Milad, „KI und IoT - Treiber der Digitalen Transformation,“ Zugriff am: 10. September 2024. [Online.] Verfügbar: <https://factory-innovation.de/artikel/ki-und-iot-treiber-der-digitalen-transformation/>
- [15] M. H. Dahm und B. Constantine, „Machine Learning für den Mittelstand,“ in *Digitale Transformation in der Unternehmenspraxis: Mindset - Leadership - Akteure - Technologien*, M. H. Dahm und S. Thode, Hg., Wiesbaden, Heidelberg: Springer Gabler, 2020, S. 327-344.
- [16] V. Demary et al., „KI-Monitor 2022: Künstliche Intelligenz in Deutschland.“ Gutachten im Auftrag des Bundesverbandes Digitale Wirtschaft (BVDW) e.V. Zugriff am: 10. September 2024. [Online.] Verfügbar: https://www.iwkoeln.de/fileadmin/user_upload/Studien/Gutachten/PDF/2022/Gutachten-KI-Monitor2022.pdf
- [17] M. Haarmeier, *Künstliche Intelligenz für den Mittelstand*. Wiesbaden: Springer Fachmedien Wiesbaden, 2021.
- [18] V. Zimmermann, „Künstliche Intelligenz: hohe Wachstumschancen, aber geringe Verbreitung im Mittelstand: In: KfW Research, Fokus Volkswirtschaft, 318.“ Zugriff am: 10. September 2024. [Online.] Verfügbar: <https://www.kfw.de/PDF/Download-Center/Konzernthemen/Research/PDF-Dokumente-Fokus-Volkswirtschaft/Fokus-2021/Fokus-Nr.-318-Februar-2021-KI.pdf>
- [19] A. Bunte, F. Richter und Diovisalvi Rosanna, „Why It is Hard to Find AI in SMEs: A Survey from the Practice and How to Promote It,“ in *International Conference on Agents and Artificial Intelligence*, 2021, S. 614-620. [Online.] Verfügbar unter: <https://api.semanticscholar.org/CorpusID:232106501>
- [20] A. Kumar und A. Kalse, „WITHDRAWN: Usage and adoption of artificial intelligence in SMEs,“ *Materials Today: Proceedings*, 2021, doi: 10.1016/j.matpr.2021.01.595.
- [21] A. Kaul, M. Schieler und C. Hans, „Künstliche Intelligenz im europäischen Mittelstand: Status quo, Perspektiven und was jetzt zu tun ist.“
- [22] Bundesministerium für Wirtschaft und Energie (BMWi), „Einsatz von Künstlicher Intelligenz in der Deutschen Wirtschaft: Stand der KI-Nutzung im Jahr 2019.“ Zugriff am: 10. September 2024. [Online.] Verfügbar: https://www.bmwk.de/Redaktion/DE/Publikationen/Wirtschaft/einsatz-von-ki-deutsche-wirtschaft.pdf?__blob=publicationFile&v=1
- [23] P. Wennker, *Künstliche Intelligenz in der Praxis: Anwendungen in Unternehmen und Branchen: KI wettbewerbs- und zukunftsorientiert einsetzen*. Wiesbaden, Germany, Heidelberg: Springer Gabler, 2020.
- [24] A. Aarstad und M. Saidl, „Barriers to adopting AI technology in SMEs,“ *Copenhagen Business School*, Copenhagen, 2019.
- [25] B. Axmann und H. Harmoko, „Herausforderungen bei der Einführung neuer digitaler Technologien bei KMU Teil 1: Am Beispiel der Künstlichen Intelligenz,“ *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, Jg. 116, Nr. 4, S. 269-271, 2021, doi: 10.1515/zwf-2021-0040.
- [26] S. Heumann und N. Jentsch, „Wettbewerb um Daten. Über Datenpools zu Innovationen.“ [Online.] Verfügbar: https://www.interface-eu.org/storage/archiv/files/wettbewerb_um_daten.pdf
- [27] D. Keim und K.-U. Sattler, „Von Daten zu KI: Intelligentes Datenmanagement als Basis für Data Science und den Einsatz Lernender Systeme.“ [Online.] Verfügbar: <https://www.acatech.de/publikation/von-daten-zu-ki-intelligentes-datenmanagement-als-basis-fuer-data-science-und-den-einsatz-lernender-systeme/download-pdf?lang=de>
- [28] M. F. Zäh, M. Ostgathe und M. Wiesbeck, „Ganzheitliches Datenmodell für kognitive Produktionssysteme,“ *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, Jg. 105, Nr. 4, S. 309-315, 2010, doi: 10.3139/104.110306.
- [29] C. Dukino, F. Kötter, T. Müller, T. Renner und H. Zaiser, „Studie: Künstliche Intelligenz anwenden - Einsatzmöglichkeiten und Methoden.“
- [30] Y. Peifer, N. Ottersböck, G. Ramm, C. Prange und H. Dander, „Künstliche Intelligenz in der Anwendung,“ in *Künstliche Intelligenz (KI) und Arbeit (ifaa-Edition)*, S. Stowasser, Hg., Berlin, Heidelberg: Springer Berlin Heidelberg, 2023, S. 27-47.
- [31] M. Harlacher et al., „Roadmap für den Weg zur eigenen KI-Lösung,“ in *Künstliche Intelligenz (KI) und Arbeit (ifaa-Edition)*, S. Stowasser, Hg., Berlin, Heidelberg: Springer Berlin Heidelberg, 2023, S. 73-105.
- [32] J. Laux, S. Wachter und B. Mittelstadt, „Trustworthy artificial intelligence and the European Union AI act: On the conflation of trustworthiness and acceptability of risk,“ *Regulation & governance*, Early Access, doi: 10.1111/rego.12512.
- [33] S. Stowasser et al., „Einführung von KI-Systemen in Unternehmen: Gestaltungsansätze für das Change-Management.“ Zugriff am: 10. September 2024. [Online.] Verfügbar: https://www.isf-muenchen.de/wp-content/uploads/2020/11/AG2_Whitepaper_Change_Management.pdf
- [34] M. Schaffner, „KI-Widerstände auf der Mitarbeiterebene in produktive Dynamik überführen,“ in *Künstliche Intelligenz in Wirtschaft & Gesellschaft: Auswirkungen, Herausforderungen & Handlungsempfehlungen (FOM-Edition)*, R. Buchkremer, T. Heupel und O. Koch, Hg., Wiesbaden, Heidelberg: Springer Gabler, 2020, S. 193-210.
- [35] C. Hunfeld, „Vier typische Anfangshürden in KI-Projekten,“ *J Oberfl Techn*, Jg. 62, Nr. 8, S. 16-17, 2022, doi: 10.1007/s35144-022-1656-5.
- [36] Seifert, Inessa, Bürger, Matthias, Wangler, Leo, Christmann-Budian, Stephanie, Rohde, Marieke, Gabriel, Peter & Zinke, Guido, „Potenziale der Künstlichen Intelligenz im Produzierenden Gewerbe in Deutschland.“ Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi) im Rahmen der Begleitforschung zum Technologieprogramm PAiCE - Platforms | Additive Manufacturing | Imaging | Communication | Engineering. Zugriff am: 10. September 2024. [Online.] Verfügbar: https://www.bmwk.de/Redaktion/DE/Publikationen/Studien/potenziale-kuenstlichen-intelligenz-im-produzierenden-gewerbe-in-deutschland.pdf?__blob=publicationFile&v=1
- [37] M. Ulrich und D. Bachlechner, „Wirtschaftliche Bewertung von KI in der Praxis - Status Quo, methodische Ansätze und Handlungsempfehlungen,“ *HMD*, Jg. 57, Nr. 1, S. 46-59, 2020, doi: 10.1365/s40702-019-00576-9.
- [38] T. Wangermann, *KI in KMU: Rahmenbedingungen für den Transfer von KI-Anwendungen in kleine und mittlere Unternehmen (Analysen & Argumente Nr. 381)*. Sankt Augustin, Berlin: Konrad-Adenauer-Stiftung, 2020. [Online.] Verfügbar unter: <https://nbn-resolving.org/urn:nbn:de:0299-202024f1c76f10c5-ea11-92c6-005056b963432>
- [39] C. Haag und N. Pyschny, „Künstliche Intelligenz für die industrielle Produktion - Ein kontextorientierter Bewertungsrahmen,“ in *Digitalisierung (Schwerpunkt Business Model Innovation)*, D. R. A. Schallmo, K. Lang, T. Werani und B. Krumay, Hg., Wiesbaden: Springer Fachmedien Wiesbaden, 2023, S. 487-512.
- [40] K.-H. Röhl und B. Engels, „Mehr Kooperation von Start-ups und Mittelstand als Chance für Digitalisierung und Innovationen,“ *Wirtschaftsdienst (Hamburg, Germany : 1949)*, Early Access, doi: 10.1007/s10273-021-2922-5.



„EIN MENSCHENZENTRIERTER ANSATZ IN DER KI-FORSCHUNG BEDEUTET, DASS DIE TECHNOLOGIE DIE ARBEIT DER MENSCHEN UNTERSTÜTZT UND NICHT ERSETZT.“



*Polina Khubbeeva,
Bundesverband der
deutschen Industrie,
Digitalisierung
und Innovation*

Algorithmen der Künstlichen Intelligenz wird ein großes Potenzial in allen Bereichen der Wertschöpfung und des alltäglichen Lebens zugeschrieben. Wie schätzen Sie den Stellenwert und das Potenzial von KI für die Produktion ein?

KI kann in der Produktion für Aufgaben wie Qualitätskontrolle, Prozessoptimierung und sogar für die Entwicklung neuer Materialien eingesetzt werden. Effizienz und Präzision werden gesteigert, generative KI kann die Fertigung zudem sicherer machen und einen Beitrag zur Überwindung von Sprachbarrieren und zur Generierung fehlender Fachkräfte leisten.

Medial findet die Entwicklung von KI in den USA und China statt. Wie schätzen Sie den Status-quo der Einführung von KI innerhalb des produzierenden Gewerbes in Deutschland ein?

Deutschland hat eine starke industrielle Basis und ist führend in der Automatisierungstechnik, was eine gute Grundlage für die Einführung von KI im produzierenden Gewerbe bietet. Es gibt jedoch noch Aufholbedarf im Vergleich zu den Entwicklungen in den USA und China, den die Politik mit gezielten Maßnahmen decken muss.

Welche Stärken kann die deutsche Industrie für die zukünftige Entwicklung ausspielen,



um die Wettbewerbsfähigkeit des Wirtschaftsstandortes Deutschland zu sichern?

Deutschlands Maschinenbauindustrie ist weltweit führend. Wir können unsere Stärken in der Qualität der Fertigung, im Ingenieurwesen und in der Ausbildung von Fachkräften nutzen, um die Entwicklung von KI voranzutreiben und die Wettbewerbsfähigkeit zu sichern.

Viele Menschen haben Angst ihren Job an die KI zu verlieren. Deshalb wird in der Forschung oftmals ein menschenzentrierter Ansatz gewählt. Wie glauben Sie, gestaltet man das Zusammenspiel zwischen Mensch und KI möglichst verträglich?

Ein menschenzentrierter Ansatz in der KI-Forschung bedeutet, dass die Technologie die Arbeit der Menschen unterstützt und nicht ersetzt. Diese Prämisse muss in Schulungen und Weiterbildungen vermittelt werden. Betriebsräte und interdisziplinäre KI-Taskforces in Unternehmen können ebenfalls helfen, das Zusammenspiel zwischen Mensch und KI in der Industrie zu verbessern.

Ein ebenfalls oft diskutiertes Thema bzgl. KI ist die Datensouveränität. Welche Lösungen brauchen wir aus Ihrer Sicht, um einerseits die Datenbasis für KI zu schaffen und andererseits das Know-how der Unternehmen zu schützen?

Für die Datensouveränität ist es wichtig, dass Unternehmen die Kontrolle über ihre Daten behalten und das Potenzial von Industriedaten gleichzeitig für die Wertschöpfung mit innovativen Geschäftsmodellen genutzt wird. Lösungen könnten zum Beispiel in kollaborativen Datenräumen oder souveränen Cloud- und Rechenlösungen liegen.

Die EU hat kürzlich als weltweit erste wichtige Regulierungsbehörde den European AI Act – eine erste Verordnung zum Einsatz von KI – beschlossen. Die allermeisten Algorithmen im produktionstechnischen Kontext werden aller Voraussicht nach der niedrigsten Risikokategorie zugeordnet. Wie stehen Sie allgemein zur Regulierung von KI und welchen Einfluss wird der AI Act auf die produzierenden Unternehmen in Deutschland und Europa nehmen?

Die Regulierung von KI ist wichtig, um Vertrauen und Sicherheit zu gewährleisten. Für die meisten produzierenden Unternehmen wird der AI Act jedoch eher eine Herausforderung darstellen. Eine zügige Entwicklung eingängiger Standards und eine industriefreundliche und inklusive Implementierung mit Berücksichtigung der anderen EU-Gesetze wie Data Act und Cyber Resilience Act ist daher enorm wichtig.



„DIE SCHLÜSSEL ZUM ERFOLG SIND REGELMÄSSIGE KOMMUNIKATION, SENSIBILISIERUNG UND SCHULUNGEN.“



*Dr. Christoph Kelzenberg,
Director Digital Innovations, Phoenix Contact*

Algorithmen der Künstlichen Intelligenz wird ein großes Potenzial in allen Bereichen der Wertschöpfung und des alltäglichen Lebens zugeschrieben. Wie schätzen Sie den Stellenwert und das Potenzial von KI für die Produktion ein?

Künstliche Intelligenz war lange Zeit eine Technologie, die in Entwicklung und Anwendung den absoluten Experten vorbehalten war. Sie genoss - und genießt weiterhin - einen hohen Stellenwert in diesen Expertenkreisen. Das Potenzial wird ebenfalls als hoch eingeschätzt - wobei man konstatieren muss, dass die Anzahl sinnvoller und funktionierender Anwendungsfälle (mit Blick auf die gesamte produzierende Industrie) dann doch begrenzt ist und diese in der Regel nicht skalieren. Mit generativer KI hält Künstliche Intelligenz nun Einzug in den (Arbeits-)Alltag nahezu aller Mitarbeitenden: Der Anwenderkreis ist signifikant größer, der Nutzen von Künstlicher Intelligenz in Form von Arbeitserleichterungen, Zeitersparnissen etc. ist direkt wahrnehmbar. Der Stellenwert und das Potenzial von Algorithmen der (generativen) Künstlichen Intelligenz werden folglich in den nächsten Monaten und Jahren erheblich steigen.



Medial findet die Entwicklung von KI in den USA und China statt. Wie schätzen Sie den Status-quo der Einführung von KI innerhalb des produzierenden Gewerbes in Deutschland ein?

Mit Blick auf das gesamte produzierende Gewerbe in Deutschland stehen wir bei der Einführung bzw. der Entwicklung und der tatsächlichen produktiven Nutzung von Künstlicher Intelligenz noch am Anfang. Insbesondere kleinere und mittlere Unternehmen, die einen Großteil der produzierenden Unternehmen darstellen, hinken den großen Unternehmen aus Kapazitätsgründen oftmals hinterher. Analog zur ersten Frage hat die Nutzung von generativer Künstlicher Intelligenz in unterschiedlichsten Anwendungsfällen auch in Deutschland dazu geführt, dass deutlich mehr Unternehmen entsprechende Lösungen einsetzen. Vor allem in den administrativen Prozessen eines Unternehmens ist dieser Trend bereits spürbar. Generell wird generative KI dem Gesamtthema KI noch mal einen Schub geben.

Viele Menschen haben Angst, ihren Job an die KI zu verlieren. Deshalb wird in der For-

schung oftmals ein menschenzentrierter Ansatz gewählt. Wie gehen Sie bei Phoenix Contact mit diesen Ängsten um und wie wollen Sie diese Herausforderung angehen?

Die Schlüssel zum Erfolg sind regelmäßige Kommunikation, Sensibilisierung und Schulungen. Über die sogenannte AI-Community informieren wir regelmäßig zu neuen Use Cases sowie zu Weiterentwicklungen von bereits im Einsatz befindlichen Lösungen, aber auch zu neuen Schulungsangeboten. Neben einer für alle Mitarbeitenden verpflichtenden, jährlich zu wiederholenden Grundlagenschulung zum Thema Künstliche Intelligenz werden bedarfsorientiert Schulungen entwickelt und angeboten, bspw. Hands-on-Schulungen zum zielführenden und mehrwertstiftenden Einsatz von Microsoft Copilot. Das Schulungsangebot wird kontinuierlich erweitert und schließt selbstverständlich auch die KI-Experten ein. Weiterhin erwähnenswert sind Vorträge und Diskussionsrunden auf Betriebsversammlungen, aber auch in individuellen Arbeits- und Regelrunden. Abschließend ist die kürzliche Installation des Corporate-AI-Managers als neue Rolle erwähnenswert; er ist zentraler Ansprechpartner für die gesamte Phoenix Contact Gruppe.



Ein ebenfalls oft diskutiertes Thema bzgl. KI ist die Datensouveränität. Welche Lösungen brauchen wir aus Ihrer Sicht bzw. welche Lösungen wollen Sie in Ihrem Unternehmen entwickeln, um einerseits die Datenbasis für KI zu schaffen und andererseits das Know-how der Unternehmen zu schützen?

Der Zugriff auf verschiedene Daten aus unterschiedlichen proprietären Informationssystemen des Unternehmens ist nicht nur für die Anwendung Künstlicher Intelligenz notwendig, sondern bereits für die erfolgreiche Umsetzung der Digitalisierung. Folglich hat Phoenix Contact in den vergangenen Jahren die Voraussetzungen für Datenverfügbarkeit und -zugriff geschaffen; eine entsprechende Organisationseinheit inkl. Prozesse ist aufgebaut und etabliert. Der Know-how-Schutz hat oberste Priorität für ein Unternehmen mit Fokus auf Technologie und Innovation. Entsprechende Voraussetzungen/Rahmenbedingungen müssen KI-Lösungen mit sich bringen, damit sie bei Phoenix Contact grundsätzlich produktiv eingesetzt werden können. Für die Einführung von Software (jeglicher Art) existiert ein dedizierter Prozess, in dessen Rahmen ein möglicher Abfluss von Daten (und damit Unternehmens Know-how) geprüft wird.



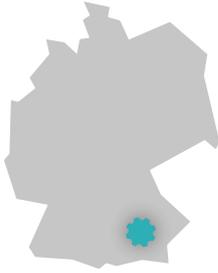
Die EU hat kürzlich als weltweit erste wichtige Regulierungsbehörde den European AI Act – eine erste Verordnung zum Einsatz von KI – beschlossen. Die allermeisten Algorithmen im produktionstechnischen Kontext werden aller Voraussicht nach der niedrigsten Risikokategorie zugeordnet. Wie stehen Sie allgemein zur Regulierung von KI und welchen Einfluss wird der AI Act auf Phoenix Contact nehmen?

Beim Thema Regulierung kommt es – wie meist – auf den richtigen Fokus und die Balance an. Dass sich Unternehmen grundsätzlich mit dem Risiko eingesetzter bzw. geplanter KI-Lösungen auseinandersetzen, ist vor allem sinnvoll, um für die Thematik zu sensibilisieren und ein tieferes Verständnis aufzubauen. Noch viel zu häufig – und das merken wir durch Austausch mit anderen Unternehmen – werden einzelne relevante Facetten zu wenig oder gar nicht beachtet. Die Regulierung darf andererseits kein ausschweifendes Maß an Bürokratie – und damit signifikanten Ressourcenaufwand – für die Unternehmen mit sich ziehen. Zu häufig erreicht man damit das Gegenteil, nämlich dass entsprechende Technologien weder erprobt noch eingesetzt werden und somit das Potenzial nicht ausgeschöpft wird. Augenmaß ist hier der richtige Begriff. Man sollte keine Angst vor KI machen, man möchte ja, dass die Unternehmen die Lösungen implementieren. Bei Phoenix

Contact kümmert sich der Corporate-AI-Manager in Zusammenarbeit mit dem Betriebsrat, Corporate HR und Compliance etc. um die Adressierung des AI Acts und die Schaffung der notwendigen Voraussetzungen.

Ein weiterhin spannendes Thema, nicht zuletzt aus der Datensicherheitsperspektive und weiterhin für die unternehmensinterne Regulierung, ist der Einsatz von generativer KI am Arbeitsplatz. Welche Strategie verfolgen Sie diesbzgl. in Ihrem Unternehmen?

Das Potenzial für generative Künstliche Intelligenz wird bei Phoenix Contact als hoch bewertet – sowohl für die Vielzahl an administrativen bzw. Unterstützungsprozessen als auch für die Wertschöpfungsprozesse. Dadurch dass (im Vergleich zu klassischer KI) nun eine deutlich größere Anzahl an Personen Zugang erhält und Lösungen anwenden kann, bedarf es einer Sensibilisierung für die Thematik. Als eines der ersten Unternehmen in Deutschland hat Phoenix Contact daher eine eigene Richtlinie für die Freigabe und den Einsatz von generativen KI-Lösungen erarbeitet und verabschiedet. Es gilt ein grundsätzliches Verbot von Lösungen der generativen KI – es sei denn diese sind freigegeben. Neben dem Prozess zur Einreichung und Freigabe von Use Cases thematisiert die Richtlinie u. a. die Schulung der Mitarbeitenden sowie den Umgang mit Lieferanten.



WIRTSCHAFTLICHKEITS- BEWERTUNG VON KI-PROJEKTEN

EIN BEISPIEL FÜR ERKLÄRBARE KI ZUR RÜSTZEITOPTIMIERUNG IN DER CNC-WERKZEUGHERSTELLUNG

Daniel Kiefer (ESB Business School), Florian Grimm (ESB Business School), Jacqueline Höllig (FZI Forschungszentrum Informatik), Tim Straub (ESB Business School), Günter Bitsch (ESB Business School), Clemens van Dinther (KIT)

KI-LÖSUNGEN AUS DER PRAXIS / STRATEGIE

Mithilfe von Modellen der erklärbaren Künstlichen Intelligenz (XAI) können die Rüstzeiten in der CNC-Werkzeugherstellung reduziert werden, wodurch nicht nur die betriebliche Effizienz und Produktionskapazität gesteigert, sondern auch die wirtschaftliche Rentabilität von KI-Projekten nachgewiesen werden kann.

Einleitung

Die Optimierung der Rüstzeiten in der CNC-Werkzeugherstellung ist ein entscheidender Faktor für die betriebliche Effizienz und die Produktionskapazität.

Längere Rüstzeiten führen zu ungenutzten Ressourcen und beeinträchtigen die Reaktionsfähigkeit auf Marktnachfragen ^[1]. Erklärbare Künstliche Intelligenz bietet hier neue Möglichkeiten, um durch die Analyse von Produktionsdaten Muster zu identifizieren und gezielte Verbesserungen vorzunehmen ^[1-4]. Abbildung 1 zeigt die zu erwartende Veränderung der Rüstzeit. KI-Projekte müssen auch nach ihrer Wirtschaftlichkeit bewertet werden, um sicherzustellen, dass die Investitionen tatsächlich einen positiven Return on Investment (ROI) bieten. Die wirtschaftliche Bewertung hilft dabei, den finanziellen Nutzen von KI-Initiativen zu quantifizieren und fundierte Entscheidungen zu treffen. Dies ist besonders wichtig, da die Implementie-

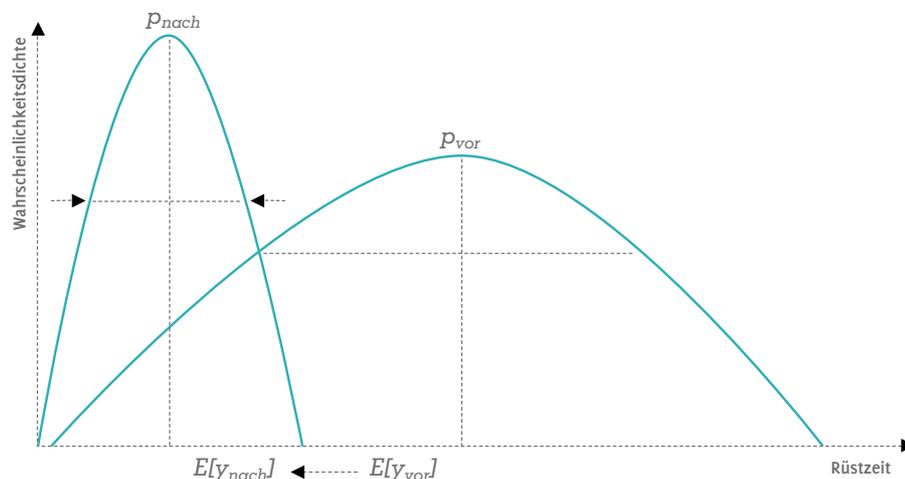


Abbildung 1: Beispiel für die zu erwartende Rüstzeit vor und nach der Verbesserung

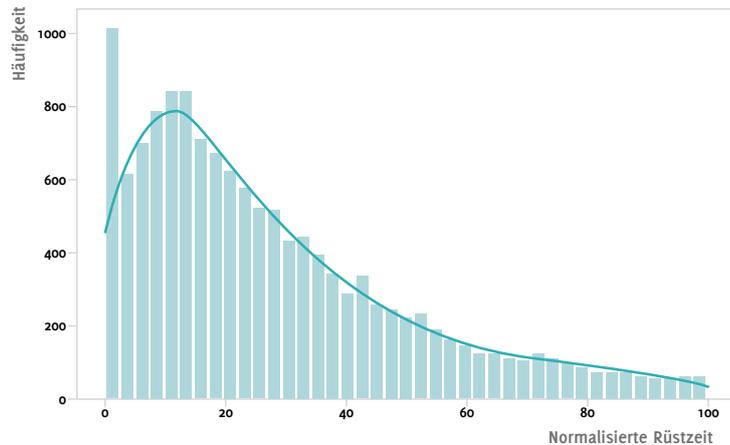


Abbildung 2: Histogramm der normalisierten Rüstzeit

zung von KI oft mit hohen Kosten und Risiken verbunden ist, die sorgfältig abgewogen werden müssen ^[5].

Erklärbare KI: Methoden und Ansätze

In komplexen betrieblichen Kontexten wird oft auf nichtlineare Machine-Learning-Modelle zurückgegriffen, um mehrdimensionale Beziehungen abzubilden ^[6]. Die Interpretation der Entscheidungsfindung in solchen Modellen ist jedoch nicht immer intuitiv ^[7]. Zur Lösung dieses Problems wurden Methoden entwickelt, die die Nachvollziehbarkeit der Schlussfolgerungen nichtlinearer Modelle verbessern. Diese Ansätze, bekannt unter dem Sammelbegriff „erklärbare KI“, fokussieren sich insbesondere auf die Analyse der Merkmalswichtigkeit und die Zuschreibung von Einflüssen auf spezifische Merkmale.

Bisher wurden die Konzepte der Merkmalswichtigkeit und der Merkmalszuordnung in der Regel unabhängig voneinander behandelt. Im Folgenden werden beide Ansätze detailliert erläutert:

- I. Die Bewertung der **Merkmalswichtigkeit** zielt darauf ab, den Einfluss einzelner Merkmale auf die Ergebnisse eines Vorhersagemodells zu bestimmen. Eine Methode ist der Vergleich der Modelleleistung mit und ohne das betreffende Merkmal, um dessen Beitrag unter Einbeziehung aller möglichen Wechselwirkungen zu bewerten. Eine weitere Methode misst die Auswirkungen auf die Vorhersagegenauigkeit bei zufälliger Modifikation eines Merkmals.

Darüber hinaus existieren modellspezifische Techniken für die Ermittlung der Merkmalswichtigkeit, wie sie bei Entscheidungsbäumen und Support-Vektor-Maschinen Anwendung finden. ^[8, 9]

- II. Die **Merkmalszuweisung** bewertet den spezifischen Beitrag eines Merkmals zur Vorhersage eines Modells. Dabei wird untersucht, inwiefern eine Veränderung des Merkmals die Vorhersage beeinflusst. In linearen Modellen wird dieser Beitrag durch die Koeffizienten dargestellt. Bei nichtlinearen Modellen kann die Merkmalszuweisung mittels partieller Abhängigkeitsdiagramme oder durch lokal interpretierbare, modellunabhängige Erklärungen erfolgen, um den Einfluss eines Merkmals auf die Vorhersage zu quantifizieren. ^[10, 11]

Die SHAP-Wert-Methode vereint die Konzepte der Merkmalswichtigkeit und -zuweisung, um die Entscheidungsfindung in Vorhersagemodellen transparent zu machen, indem sie Vorhersagen in einzelne Merkmalsbeiträge, die sogenannten SHAP-Werte, aufgliedert. Sie basiert auf der Kombination aus lokalen Modellerklärungen und spieltheoretischen Prinzipien, wobei SHAP-Werte individuell für jede Beobachtung innerhalb eines Merkmalsvektors berechnet werden ^[12]. Diese Methode erlaubt eine detaillierte Analyse sowohl auf lokaler als auch auf globaler Ebene und findet in dieser Arbeit Anwendung, um komplexe Zusammenhänge zwischen Produktionsparametern und der Rüstzeit in dem nachfolgend beschriebenen Fertigungssystem zu entschlüsseln.



Anwendung in der CNC-Werkzeugherstellung

Unser Anwendungspartner, ein führendes deutsches KMU in der Produktion von Präzisionswerkzeugen, hat uns historische Daten von 1.875 Rüstvorgängen bereitgestellt. Diese Daten umfassen 144 Produktionsparameter von 8 verschiedenen Maschinen. Die Rüstzeit, deren Wert es zu reduzieren gilt, wurde zwischen 0 und 100 skaliert, um vertrauliche Informationen zu schützen und dennoch die Verteilungsmuster zu erhalten.

Implementierung des Modells

Das entwickelte Modell basiert auf XGBoost^[13], einem Boosting-Baum-Ensemble-Algorithmus. Es wird mit historischen Daten trainiert und die Merkmalszuordnungen aller Produktionsparameter werden mithilfe der Baumimplementierung der SHAP-Wert-Methode berechnet.

Ergebnisse

Die Analyse historischer Rüstprozesse zeigt, dass durch das Modell die normalisierte Rüstzeit reduziert

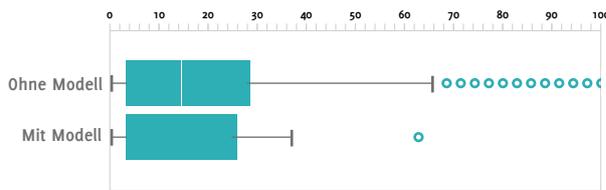


Abbildung 3: Modell-Effekte

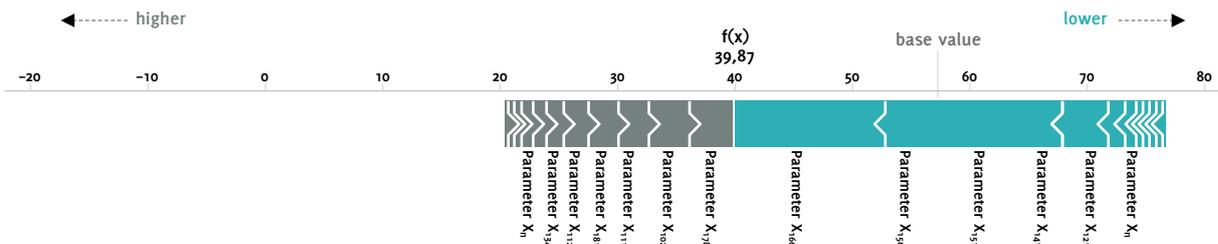


Abbildung 4: Beispiel für eine Vorhersage der Rüstzeit an einer Maschine

werden kann. Der Boxplot der prognostizierten Effekte zeigt, dass durch das Modell die Ausreißer um etwa 90 % reduziert werden können und die mittlere normalisierte Rüstzeit gesenkt wird.

Praktische Umsetzung und Vorteile

Durch die Visualisierung der Vorhersagen und der SHAP-Werte erhält der Arbeiter entscheidende Informationen, um die am besten geeignete Maschine für den nächsten Produktionsauftrag auszuwählen. Dies führt zu einer Reduktion der normalisierten Rüstzeit-

ten um etwa 6 %, was zu einer Steigerung der Produktivität und einer Senkung der Betriebskosten führt. Erste Schätzungen gehen davon aus, dass über 4.500 zusätzliche Werkzeuge im Jahr gefertigt werden können, allein in der betrachteten Arbeitsplatzgruppe.

Wirtschaftliche Betrachtung

Die wirtschaftliche Betrachtung von KI-Projekten ist entscheidend, um den finanziellen Nutzen und die langfristige Rentabilität zu bewerten.



Eine einfache Methode zur Bewertung ist die Berechnung des ROI, der das Verhältnis des Nettonutzens eines Projekts zu den Investitionskosten darstellt. Ein positiver Wert zeigt an, dass das Projekt mehr einbringt, als es kostet ^[14].

$$ROI = \frac{\text{Ertrag der Investition} - \text{Investitionskosten}}{\text{Investitionskosten}} \times 100$$

Hierbei ist:

- Ertrag der Investition: Der finanzielle Ertrag, den das Projekt generiert, abzüglich aller Kosten, die direkt mit der Investition verbunden sind.
- Investitionskosten: Die Gesamtkosten der Investition, einschließlich aller Ausgaben für die Implementierung und den Betrieb des Projekts.

Der interne Zinsfuß (IRR) ist eine zentrale Kennzahl in der Investitionsrechnung, die den Abzinsungssatz darstellt, bei dem der Nettobarwert eines Projekts gleich null ist. Er gibt somit die durchschnittliche jährliche Rendite an, die ein Projekt während seiner Laufzeit generiert ^[15]. Zur Bewertung von KI-Projekten bietet der IRR eine wichtige Perspektive, da er die zeitliche Verteilung der Cashflows berücksichtigt und somit den Zeitwert des Geldes in die Analyse einbezieht. Dies ist besonders wichtig für KI-Projekte, die oft hohe Anfangsinvestitionen und langwierige Entwicklungsphasen aufweisen, bevor sie zu Cashflows führen. Ein hoher IRR signalisiert, dass ein KI-Projekt potenziell hohe Renditen generiert und somit wirtschaftlich attraktiv ist.

IRR > Kapitalkosten: Das Projekt ist wirtschaftlich attraktiv und sollte in Erwägung gezogen werden.

IRR < Kapitalkosten: Das Projekt ist nicht wirtschaftlich attraktiv und sollte möglicherweise abgelehnt werden.

IRR = Kapitalkosten: Das Projekt erzielt eine Rendite, die genau den Kapitalkosten entspricht.

Darüber hinaus kann der Net Present Value (NPV) verwendet werden, um den aktuellen Wert zukünftiger Cashflows zu berechnen, die durch das KI-Projekt generiert werden. Der NPV berücksichtigt den Zeitwert des Geldes und bietet eine detaillierte Einschätzung der finanziellen Attraktivität des Projekts. Ein positiver

NPV zeigt, dass das Projekt voraussichtlich mehr Wert schafft, als die anfänglichen Investitionen kosten, und somit wertschöpfend ist. Diese Formel berechnet den Barwert (Present Value) aller zukünftigen Cashflows, abgezinst auf den heutigen Wert, und zieht davon die anfänglichen Investitionskosten ab. Ein positiver NPV zeigt an, dass das Projekt wertschöpfend ist ^[16].

$$NPV = \sum_{t=0}^n \frac{R_t}{(1+r)^t} - C_0$$

Wobei:

- R_t der Netto-Cashflow im Zeitraum t ist
- r der Diskontsatz (oder Abzinsungsfaktor) ist
- t der Zeitabschnitt ist (z. B. Jahre)
- n die Anzahl der Zeitabschnitte ist
- C_0 die anfänglichen Investitionskosten sind

Im Folgenden berechnen wir beispielhaft den ROI, den IRR und den NPV für unseren Anwendungsfall:

Projektbeschreibung

- Projektlaufzeit: 2 Jahre Entwicklungsphase, 1 Jahr Implementierung, Betrieb ab Jahr 4
- Kosten: Entwicklungskosten über 2 Jahre, Implementierungskosten im Jahr 3
- Einnahmen: erhöht ab Jahr 4 durch optimierte Prozesse und gestiegenen Output

Annahmen für das Projekt

- Entwicklungskosten: 200.000 EUR pro Jahr für 2 Jahre
- Implementierungskosten im Jahr 3: 100.000 EUR
- Wartungskosten im Jahr ab Jahr4: 30.000 EUR
- Zusätzliche Einnahmen ab Jahr 4: 186.595 EUR pro Jahr durch Rüstzeitoptimierung und gestiegenen Output
- Projektdauer zur Betrachtung: 8 Jahre (2 Jahre Entwicklung + 1 Jahr Implementierung + 5 Jahre Betrieb)

Im ersten Schritt wird der ROI berechnet:

$$ROI = \frac{932.979 - 450.000}{450.000} \times 100 = 207 \%$$



Im zweiten Schritt wird der IRR berechnet:

Jahr	Entwicklungs- kosten	Implementie- rungskosten	Wartungs- kosten	Einnahmen (EUR)	Cashflow
1	-200.000	0	0	0	-200.000
2	-200.000	0	0	0	-200.000
3	0	-100.000	0	0	-100.000
4	0	0	-30.000	186.595	156.595
5	0	0	-30.000	186.595	156.595
6	0	0	-30.000	186.595	156.595
7	0	0	-30.000	186.595	156.595
8	0	0	-30.000	186.596	156.595
IRR					22 %

BETRACHTUNG DER FINANZKENNZAHLEN ÜBER DIE JAHRE

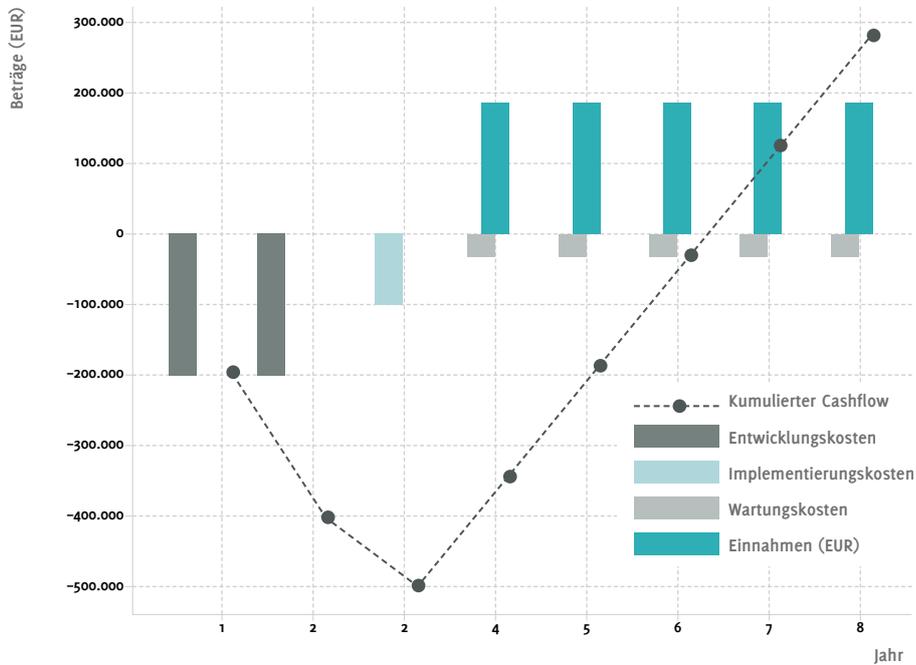


Abbildung 5: Betrachtung der Finanzkennzahlen über die Jahre

Im dritten Schritt wird der NPV berechnet:

$$NVP = -200.000 - \frac{200.000}{1,1} - \frac{100.000}{1,1^2} + \frac{156.000}{1,1^3} + \frac{156.000}{1,1^4} + \frac{156.000}{1,1^5} + \frac{156.000}{1,1^6} + \frac{156.000}{1,1^7} = 191.422 \text{ €}$$

In der Bewertung des vorliegenden KI-Projekts wurden drei zentrale finanzielle Kennzahlen analysiert: der Return on Investment (ROI), die Internal Rate of Return (IRR) und der Net Present Value (NPV). Die Ergebnisse zeigen durchweg positive Indikatoren für die potenzielle Wirtschaftlichkeit des Projekts.

Der ROI von 207 % übersteigt den Schwellenwert von 100 %, ab dem ein Projekt als profitabel gilt. Dieser Wert impliziert, dass das Projekt mehr als das Dreifache des initial investierten Kapitals generieren würde, was auf eine außerordentlich effiziente Kapitalallokation hindeutet.



Mit einem IRR von 22 % demonstriert das Projekt eine beachtliche jährliche Rendite. Dieser Wert liegt deutlich über den in der Regel angesetzten Kapitalkosten vieler Unternehmen, was die attraktive Renditestruktur des Projekts unterstreicht.

Der positive NPV von 191.422 bestätigt, dass das Projekt auch unter Berücksichtigung des Zeitwerts des Geldes einen substantziellen Mehrwert für das Unternehmen schafft. Diese Kennzahl ist besonders relevant für die langfristige strategische Bewertung des Projekts. In der Gesamtbetrachtung weisen alle drei Kennzahlen konsistent auf ein Projekt mit überdurchschnittlichem wirtschaftlichem Potenzial hin. Zudem wäre eine Sensitivitätsanalyse empfehlenswert, um die Robustheit der Ergebnisse unter verschiedenen Szenarien zu überprüfen.

Abschließend lässt sich konstatieren, dass das evaluierte KI-Projekt basierend auf den vorliegenden finanziellen Indikatoren eine vielversprechende Investitionsmöglichkeit darstellt, die eine eingehende weiterführende Prüfung und Berücksichtigung im Rahmen der Unternehmensstrategie indiziert.

Zusammenfassung und Ausblick

Die positiven Ergebnisse unterstreichen das Potenzial erklärbarer KI in der CNC-Werkzeugeherstellung zur Rüstzeitoptimierung. Zukünftige Forschungen sollten die Genauigkeit von KI-Prognosen verbessern, die Integration in Planungssysteme vorantreiben und benutzerfreundliche Schnittstellen entwickeln, um KI-Entscheidungen verständlicher zu machen. Die Möglichkeit, KI-Projekte für Unternehmen ökonomisch vorteilhaft zu nutzen, wurde aufgezeigt.

Literatur

- [1] Mourtzis, D., Doukas, M., 2014. The Evolution of Manufacturing Systems, in Handbook of Research on Design and Management of Lean Production Systems, IGI Global, p. 1.
- [2] Ulrich, P., Frank, V., Kratt, M., 2021. Adoption of artificial intelligence technologies in German SMEs – Results from an empirical study, in Corporate governance: A search for emerging trends in the pandemic times, Virtus Interpress, p. 76.
- [3] Bauer, M., van Dinther, C., Kiefer, D., 2021. Machine learning in SME: An empirical study on enablers and success factors 1.
- [4] Zennaro, I., Finco, S., Battini, D., Persona, A., 2019. Big size highly customised product manufacturing systems: a literature review and future research agenda 57, p. 5362.
- [5] Jamal, A., Sarker, B.R., Mondal, S., 2004. Optimal manufacturing batch size with rework process at a single-stage production system 47, p. 77.
- [6] Cui, R., Gallino, S., Moreno, A., Zhang, D.J., 2018. The Operational Value of Social Media Information 27, p. 1749.
- [7] Guidotti, R., Monreale, A., Ruggieri, S., Turini, F. et al., 2019. A Survey of Methods for Explaining Black Box Models 51, p. 1.
- [8] Guyon, I., Weston, J., Barnhill, S., Vapnik, V., 2002. Gene Selection for Cancer Classification using Support Vector Machines 46, p. 389.
- [9] Breiman, L., 2001. Random forests 45, p. 5.
- [10] Ribeiro, M.T., Singh, S., Guestrin, C., 2016. „Why Should I Trust You?“, in Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, New York, USA, p. 1135.
- [11] Friedman, J.H., 2001. Greedy Function Approximation: A Gradient Boosting Machine 29, p. 1189.
- [12] Lundberg, S.M., & Lee, S., 2017. A Unified Approach to Interpreting Model Predictions. Neural Information Processing Systems., in.
- [13] Chen, T., Guestrin, C., 2016. XGBoost, in Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, New York, USA, p. 785.
- [14] Botchkarev, A., Andru, P., 2011. A Return on Investment as a Metric for Evaluating Information Systems: Taxonomy and Application 6, p. 245.
- [15] Magni, C.A., 2010. Average Internal Rate of Return and Investment Decisions: A New Perspective 55, p. 150.
- [16] Osborne, M.J., 2010. A resolution to the NPV-IRR debate? 50, p. 234.

DIGITALISIE



WEGWEISER

In diesem Kapitel thematisieren wir die Digitalisierung als notwendige Grundlage für den Einsatz von KI. Von der Maschinenanbindung über Cloud-Infrastrukturen bis zum KI-Deployment in der Produktion: Dieses Kapitel behandelt das breite Spektrum der Digitalisierung. Wie in Kapitel „Daten“ beschrieben, brauchen Algorithmen der Künstlichen Intelligenz Daten, die u. a. aus den Maschinen- und Anlagensteuerungen – in manchen Anwendungen sogar prozessparallel und in Echtzeit – aufgenommen werden müssen. Weiterhin sind die enormen Datenmengen beispielsweise in der Cloud oder auf alternativer Infrastruktur zu speichern. Die trainierten Algorithmen sollten möglichst standardisiert in die produktionsnahen Softwareumgebungen integriert (Deployment) und – genau wie bei physischen Maschinen auch – ist eine kontinuierliche Wartung vorzusehen.

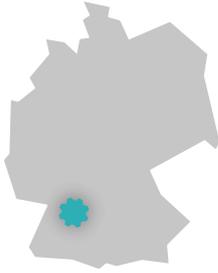


RUNG

**PRAXISBEISPIELE, DIE
AUFZEIGEN, WIE SIE
IHRE INFRASTRUKTUR
FÜR DEN KI-EINSATZ
FIT MACHEN.**



- 
- 76** KI-Implementierung in der Produktionstechnik vereinfacht
AutoLern
- 81** Cloudgestützte KI-Anwendung für den Medikamentendruck
ProKInect
- 86** Kollaboratives Condition Monitoring Herstellerübergreifende Fehlerdiagnose von Werkzeugmaschinen
ProKInect
- 90** Mit OPC UA zur intelligenten Fertigung: KI-Anwendungen einfach entwickeln und skalieren
KausaLAssist
- 93** Befähigung von Werkzeugmaschinen für eine Machine-Learning-basierte Werkzeugüberwachung
TransKI
- 97** Echtzeit Prozessüberwachung beim Laser Blanking
DIPool



KI-IMPLEMENTIERUNG IN DER PRODUKTIONS- TECHNIK VEREINFACHT

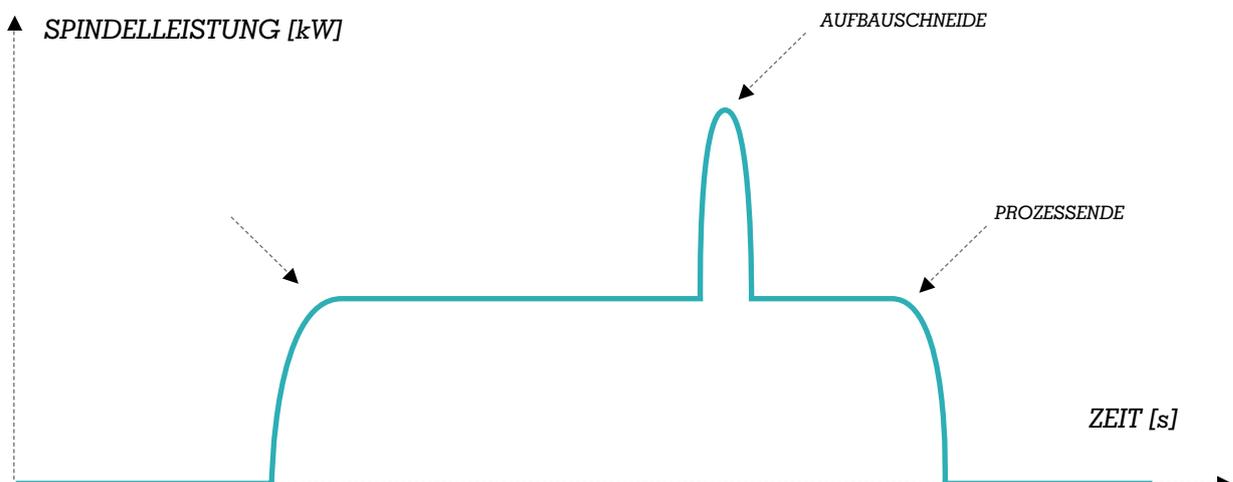
Immanuel Heider, Marvin Frisch (wbk Institut für Produktionstechnik des Karlsruher Instituts für Technologie, KIT)

Für die Künstliche Intelligenz besteht in der Produktionstechnik enormes Potenzial. Ihrem umfassenden Einsatz steht jedoch eine Hürde gegenüber: die Implementierung auf dem Shopfloor.

Der Einsatz von Künstlicher Intelligenz ist in Anwendungsfällen sinnvoll, in denen die Entwicklung einer analytischen Lösung aufwendig, zeitintensiv oder gar unmöglich ist. KI kann große Datenmengen schnell und präzise verarbeiten, komplexe Muster erkennen

und aus diesen Erkenntnissen Vorhersagen treffen. Ein Beispiel hierfür ist die Erkennung einer Aufbauschneide beim Drehen zäher Werkstoffe anhand der Spindelleistung. Die Aufbauschneide – eine unerwünschte Materialansammlung an der Schneidkante des Werkzeugs – führt zu zahlreichen negativen Effekten wie zum Beispiel vorzeitigem Werkzeugverschleiß und verminderter Oberflächengüte. Im zeitlichen Verlauf der Spindelleistung zeichnen sich hierbei Ausschläge und Schwingungen ab, die für den menschlichen Betrachter als Anomalien ersichtlich sind. Eine qualitative Darstellung ist in Abbildung 1 gegeben.

Abbildung 1 Spindelleistung einer Drehmaschine im zeitlichen Verlauf (qualitativ) und der Ausschlag infolge einer Aufbauschneide





Die formelmäßige Beschreibung dieser Anomalien ist jedoch herausfordernd bis unmöglich. Durch den Einsatz von Methoden der Künstlichen Intelligenz wird Abhilfe geschaffen. Beispielsweise ist die Auswertung der Spindelleistung durch ein neuronales Netz zielführend. Das neuronale Netz ist in der Lage Zusammenhänge zwischen dem zeitlichen Verlauf der Spindelleistung und dem Vorliegen bzw. dem Ausbleiben einer Aufbauschneide zu erlernen.

In vielen Fällen stellen die Entwicklung und das Training des KI-Modells (hier z. B. ein neuronales Netz) ein überschaubares Problem dar. Leistungsfähige KI-Bibliotheken sind leicht verfügbar. Beispielsweise bieten die Python-Bibliotheken PyTorch und TensorFlow vorgefertigte Funktionen und Modelle, die die Entwicklung von KI-Modellen vereinfachen. PyTorch wurde von Facebook entwickelt, während TensorFlow von Google stammt. Beide werden als Open-Source-Software bereitgestellt, was bedeutet, dass sie frei zugänglich sind und von einer großen Gemeinschaft kontinuierlich weiterentwickelt werden. Dadurch können Entwickler schnell auf bewährte Werkzeuge zugreifen und diese in ihre eigenen Projekte integrieren, ohne von Grund auf neue Lösungen entwickeln zu müssen.

Im Kontext der Produktionstechnik liegt die Herausforderung daher oftmals nicht in der Entwicklung des KI-Modells, sondern in der Erhebung von Trainingsdaten, die das Modell benötigt, um aussagekräftig zu werden, sowie im Schaffen der Infrastruktur für dessen Einsatz an der Maschine. Im Rahmen des Projektes AutoLern wurde ein Konzeptentwurf entwickelt und umgesetzt, der sich der Herausforderung der

Infrastruktur widmet. Die hierfür benötigten Funktionalitäten und der Ansatz des Projektes werden nachfolgend vorgestellt.

KI-Implementierung: Welche Funktionsbereiche werden benötigt?

Das zentrale Element einer einsatzfähigen KI-Anwendung ist das KI-Modell. Damit dieses Modell jedoch nützliche Ergebnisse liefern kann, ist eine geeignete Infrastruktur erforderlich. Diese Infrastruktur muss sicherstellen, dass Rohdaten erfasst, sofern notwendig vorverarbeitet und bei Bedarf gespeichert werden, bevor sie dem Modell zur Analyse zugeführt werden. Die Aussage des Modells wird daraufhin entweder einer weiteren Applikation zugeführt (z. B. einer Steuerung oder Regelung), oder an einen menschlichen Benutzer kommuniziert. Aus diesen Anforderungen ergibt sich eine Aufteilung der Funktionalitäten, die diese bereitstellen muss, in 5 grundlegende Funktionsbereiche, die in Abbildung 2 dargestellt sind.

Der Funktionsbereich der Datenaufnahme ist für die Erfassung von Rohdaten verantwortlich. Im produktionstechnischen Umfeld können Datenquellen Sensoren wie Temperatur- oder Beschleunigungsaufnehmer sein. Darüber hinaus stellen Maschinensteuerungen Informationen wie zum Beispiel Strom- und Positionssignale bereit. Durch die Vielfalt unterschiedlicher Sensor- und Maschinenschnittstellen sind verschiedene Kommunikationsmöglichkeiten zur Übertragung von Rohdaten gegeben. Zielführend ist daher, die Datenaufnahme so zu gestalten, dass sie in der Lage ist, eine Vielzahl verschiedener Kommunikationsstandards

Abbildung 2 Funktionsbereiche, die für die Implementierung einer KI-Lösung benötigt werden





abzudecken beziehungsweise „die Sprachen“ zahlreicher Typen von Maschinen und Sensoren zu verstehen. Der Funktionsbereich Kommunikation wickelt die Verteilung von Daten unter den weiteren Funktionsbereichen ab. Rohdaten, die über die Datenaufnahme eingehen, werden über die Kommunikation an weitere Komponenten verteilt. Eine flexible Kommunikationslösung sind sogenannte „Broker-basierte“ Systeme. In gewisser Analogie zum Versenden von Briefen müssen bei der Nutzung von Brokern alle interessierten Parteien nicht in einer direkten Kommunikation miteinander stehen. Jeder Absender bringt seine Briefe zum Postamt. Das Postamt sortiert diese und stellt sicher, dass jeder Brief an den richtigen Empfänger zugestellt wird. Die Funktionsbereiche müssen also nicht im direkten Kontakt zueinander stehen, sondern bezie-

hen Nachrichten von einer zentralen Einheit (siehe beispielsweise auch Abbildung 3). Der Broker erlaubt damit eine schnelle Erweiterung des Systems. Wenn die Prognose des KI-Modells an zusätzliche Konsumenten verteilt werden soll oder wenn das System um ein zusätzliches Modell erweitert wird, müssen diese neuen Funktionsbereiche nur die Kommunikation mit dem Broker konfigurieren. Der dritte Funktionsbereich, die Verarbeitung, umfasst das KI-Modell selbst sowie die Vorverarbeitung. Die Vorverarbeitung bezieht sich auf Schritte, die durchgeführt werden, um Rohdaten in eine Form zu übersetzen, die ein Modell verarbeiten kann. Die vorverarbeitete Form der Daten wird auch als Feature bezeichnet. Beispiele für die Vorverarbeitung sind Filterung und Skalierung der Rohdaten auf vordefinierte Wertebereiche sowie das

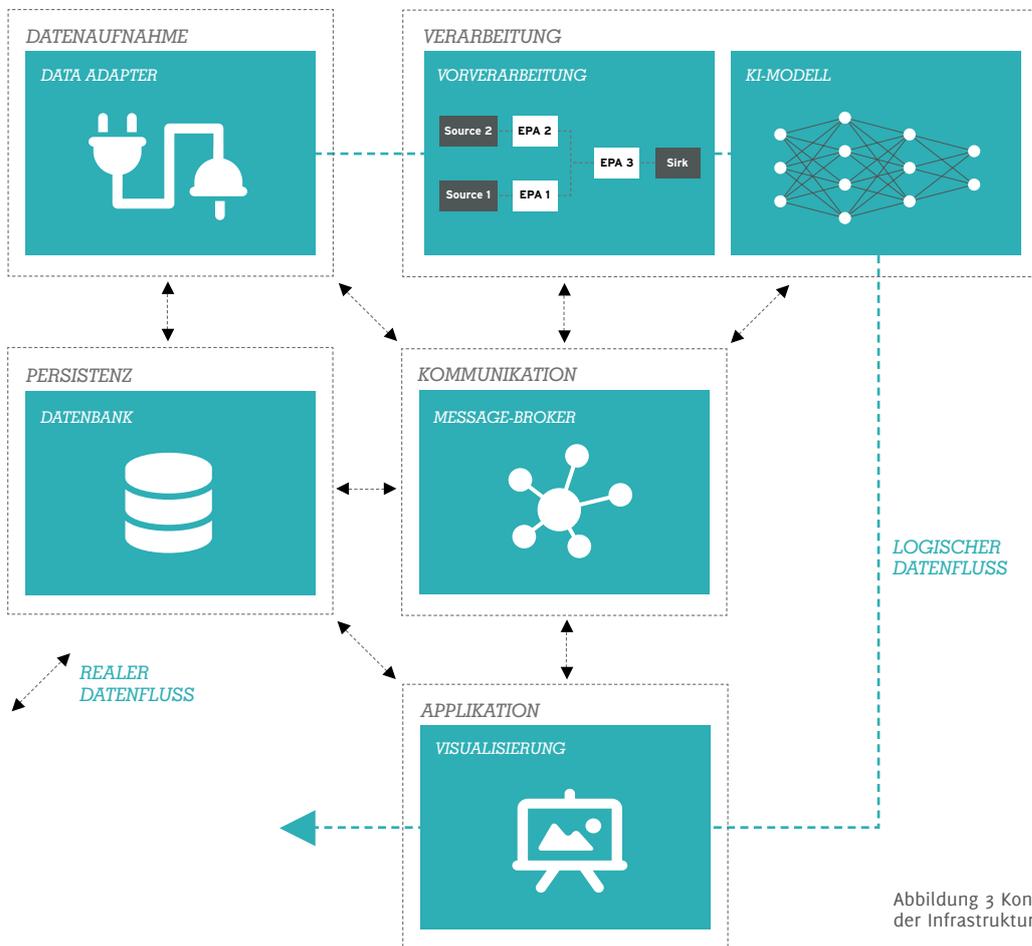


Abbildung 3 Konzeptionelle Darstellung der Infrastruktur für den KI-Einsatz



Anpassen der eingehenden Daten auf eine konstante Größe. Ein KI-Modell rechnet mit einem Eingangs-Feature, welches genau 100 Werte enthält. Wenn die Rohdaten jedoch eine davon abweichende Anzahl an Datenpunkten enthalten, kann es notwendig sein, dass Daten entweder abgeschnitten werden, oder weitere Datenpunkten aus vorherigen Zeitschritten hinzugefügt werden. Als Persistenz wird das Abspeichern von Daten bezeichnet. Gespeichert werden in der Regel Rohdaten, Features und die Aussagen des Modells, um die Rückverfolgbarkeit von Ergebnissen zu ermöglichen. Dabei kommen Datenbanken zum Einsatz. Bei der Arbeit mit Zeitreihendaten eignen sich spezielle Zeitreihendatenbanken. Der als Applikation bezeichnete Funktionsbereich liefert den eigentlichen Mehrwert der KI-Anwendung. Er setzt die Aussage eines Modells in eine Form um, die für den menschlichen Nutzenden verständlich und nützlich ist. Im einfachsten Fall kann dies eine Visualisierung sein, wie zum Beispiel eine Anzeige, die den aktuellen Zustand einer Maschine oder eines Prozesses bewertet. Ein weiteres Beispiel ist die Ausgabe einer Benachrichtigung, sobald eine Maschinenkomponente oder ein Werkzeug einen kritischen Verschleißzustand erreichen. Damit wird beispielsweise der Service-Einsatz an einer Maschine planbar und es entstehen keine Notsituationen.

Abbildung 3 zeigt, wie die vorgestellten Funktionsbereiche angeordnet werden können, um dem den Konzeptentwurf für den KI-Einsatz zu bilden.

Der graue Pfeil stellt die chronologische bzw. logische Abfolge dar, in welcher der Informationsfluss von der Datenaufnahme bis zur Nutzung der Ausgabe des KI-Modells erfolgt.

Die schwarzen Pfeile zeigen den tatsächlichen Datenfluss zwischen den Funktionsbereichen und dem Broker. Nicht dargestellt ist die Datenquelle, die je nach Anwendungsfall unterschiedlich sein kann. Datenquellen sind in der produktionstechnischen Anwendung in der Regel Sensorik sowie die Steuerungen von

Maschinen, wie speicherprogrammierbare Steuerungen (SPS) oder numerische Steuerungen (Computer Numerical Control bzw. CNC).

KI-Implementierung: Umsetzung des Konzeptentwurfs

Der Aufbau des Implementierungskonzepts und die Wahl der Werkzeuge, die dabei zum Einsatz kommen, sind in Abbildung 4 dargestellt. Die Gestaltung motiviert sich durch folgende zwei Anforderungen:

- Direkte Nutzung der Funktionsbereiche bei geringer Neuentwicklung, wenn ein KI-Modell in einem neuen Anwendungsfall eingesetzt werden soll
- Anbindung an unterschiedliche Datenquellen

Die in Abbildung 4 aufgeführten Komponenten sind eigenständige Unterprogramme. Diese Modularität ermöglicht eine Wiederverwendung über mehrere Anwendungsfälle hinweg. Ferner wird dadurch ermöglicht, dass bei der (Neu-)Entwicklung einzelner Komponenten andere Komponenten nicht berücksichtigt werden müssen. Der Message-Broker sowie die Datenbank sind zum Beispiel zwei Funktionsbereiche, die über eine Vielzahl von verschiedensten Anwendungsfällen hinweg unverändert bleiben können. Gegebenenfalls wird eine Umkonfiguration notwendig, jedoch kein zusätzlicher Entwicklungs- bzw. Programmieraufwand. Ähnlich wie KI-Bibliotheken für die KI-Modelle, stehen Open-Source-Werkzeuge auch für die Umsetzung des Konzeptentwurfs bereit. Die Entwickler frei beziehen und für ihren Anwendungsfall zuschneiden können. Die Datenaufnahme mit dem Werkzeug Telegraf gestaltet sich einfach. Durch Anpassung von Konfigurationsdateien (im Wesentlichen sind dies einfache Textdateien) kann schnell und einfach definiert werden, mit welcher Datenquelle in welcher „Sprache“ kommuniziert wird. Die Datenbank InfluxDB (ebenfalls von den Entwicklern von InfluxDB erstellt), ist mit Telegraf standardmäßig integrierbar, sodass die Aufnahme und direkte Speicherung von Rohdaten keine Herausforderung darstellt.



Auch der Message-Broker RabbitMQ lässt sich auf diese Weise einstellen. Durch Spezifikationen in Konfigurationsdateien wird definiert, wie mit welchen Funktionsbereichen Daten ausgetauscht werden. Ein bekanntes Werkzeug zur Visualisierung von Livedaten ist Grafana. Hier ist es sogar möglich, Datenströme über eine grafische Benutzeroberfläche darzustellen. Die Darstellung erfordert somit keinen Programmieraufwand – sie lässt sich „zusammenklicken“. Ein Funktionsbereich, der jedoch stets Eigenentwicklung erfordert, ist die Datenverarbeitung. Das Erstellen und Trainieren des KI-Modells sowie die Programmierung der dazu passenden Vorverarbeitung sind für jeden Anwendungsfall spezifisch.

Ziel des Implementierungskonzeptes war es, eine Infrastruktur für den KI-Einsatz in der Produktionstechnik zu entwickeln, die es weniger erfahrenen Entwicklern sowie Ingenieuren mit Interesse am Programmieren ermöglicht, schnell eine prototypische, aber voll lauffähige KI-Applikation im industriellen Kontext aufzusetzen. Die Funktionsbereiche der Datenaufnahme, Persistenz, Kommunikation und Visualisierung lassen sich derart anordnen, dass eine Anpassung entweder einfach ist oder vollständig entfällt. Dem Anwender wird es hiermit möglich, sich auf das Wesentliche zu konzentrieren: die Entwicklung und das Training des eigenen KI-Modells.

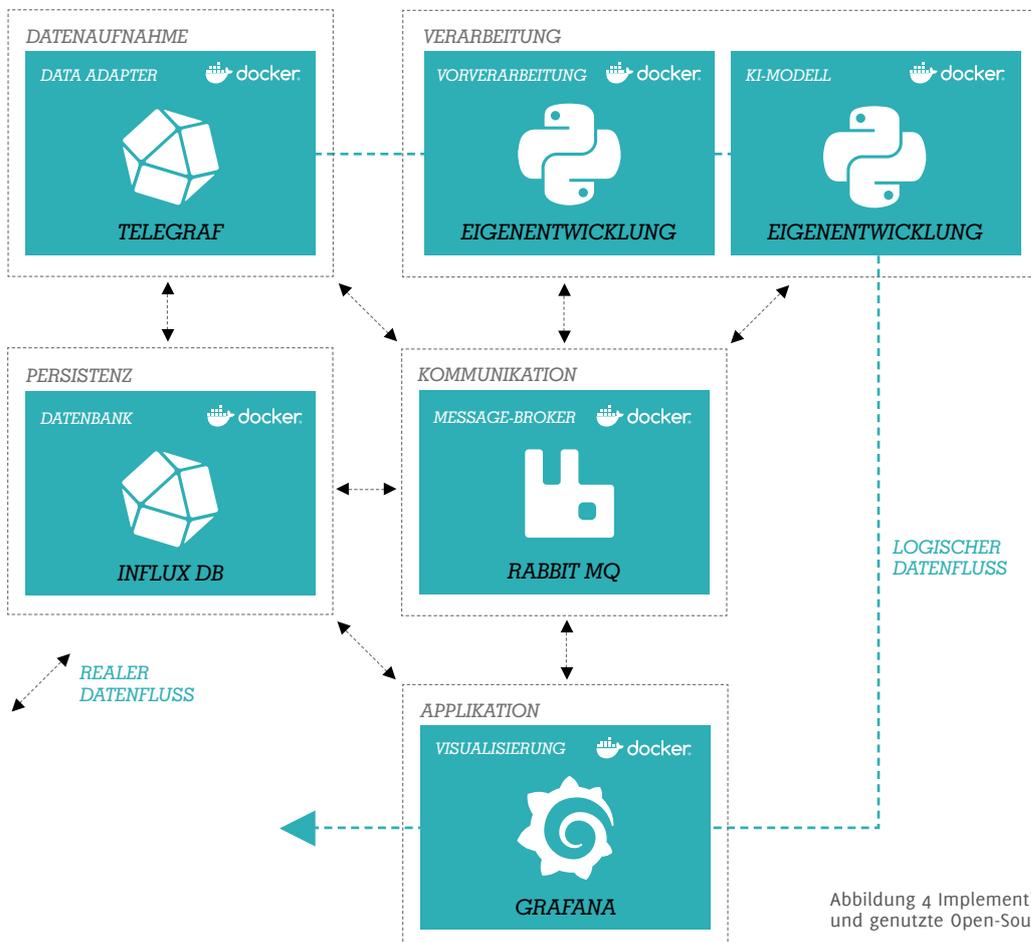
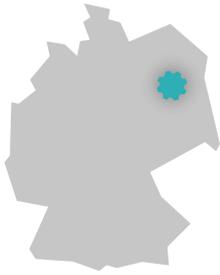


Abbildung 4 Implementierung der Infrastruktur und genutzte Open-Source-Werkzeuge



CLOUDGESTÜTZTE KI-ANWENDUNG FÜR DEN MEDIKAMENTENDRUCK



Jochen Lutz (Digital Health Systems GmbH), Michael Hoffer (Hamilton Freiburg GmbH), Ralf Schallert (Relimetrics GmbH), Raz Flieshman (TU Berlin, Institut für Werkzeugmaschinen und Fabrikbetrieb – IAT), Joachim Gnauk (PSI Metals GmbH)

Ein cloudbasierter Ansatz zur Vernetzung von ML-Aktivitäten erhöht die Produktsicherheit im Medikamentendruck.

Zusammenfassung

Der Demonstrator Medikamentendruck integriert Projektteile des Förderprojekts KIKa-IPK. Ziel war die verbesserte Qualitätskontrolle, Kalibrierung und Regelung beim Druck von patientenindividuellen Medikamenten auf Dünnfilm mithilfe von Künstlicher Intelligenz (KI). Zusammen mit den Projektpartnern IAT, PSI und Relimetrics wurden zwei sichtbare Qualitätskontrollen in KI-gestützte Prozesse umgesetzt:

1. KI-basierte Volumenregelung der aufgetragenen wirkstoffhaltigen Flüssigkeit in Form von Tropfen im BioFludix Dispenser (ALLDROP®)
2. die KI-basierte optische Qualitätskontrolle der Flüssigkeitsverteilung auf Dünnfilmen (ODF) im DiHeSys-Drucker

Anwendungsfall

Die gestellte Aufgabe war, die nasschemische Labo-analyse durch weniger aufwendige, KI-gestützte Verfahren zu ersetzen. Es gibt hierfür drei Anforderungen:

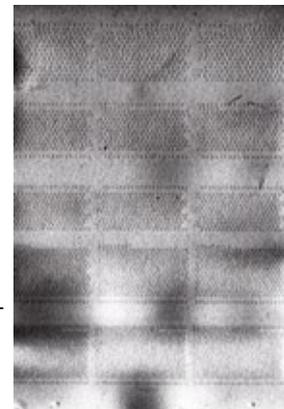


Abbildung 1: Bedruckter Dünnfilm

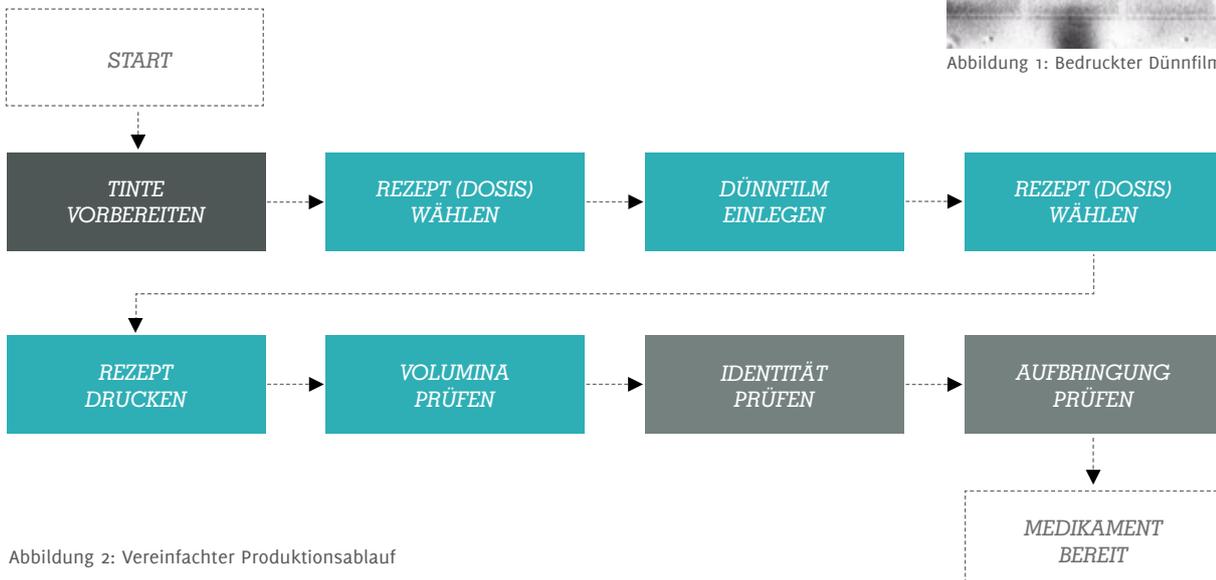


Abbildung 2: Vereinfachter Produktionsablauf



1. Erkennung der Identität des Wirkstoffs
 2. Messung der Quantität des aufgetragenen Wirkstoffs
 3. Prüfung der Qualität der Auftragung
- Sind diese Anforderungen erfüllt, so kann das produzierte Medikament abgegeben werden.

Hintergrund

Der Flexdose-Printer druckt individuelle Dosen von flüssigen (gelösten) Wirkstoffen auf ein verzehrbares Dünnschichtblatt in 15 Stücken. Ein Druckkopf wird über das Dünnschichtblatt bewegt und gibt dabei Tropfen in geeignetem Mustern und Schichten ab. Die einzelnen Stücke werden zur Abgabe anschließend einzeln verpackt.

Produziert wird nach folgendem Prozess:

Demonstration: Qualitätskontrolle, Kalibrierung und Regelung beim Medikamentendruck

Beschreibung

Die weitere Beschreibung erfolgt entlang des oben genannten Produktionsablaufs und erläutert die verschiedenen Komponenten und Systeme.

Verwendete Cloud-Plattform

Für die ineinandergreifenden KI-Prozesse kommt eine einheitliche Cloud-Server-Plattform zum Einsatz.

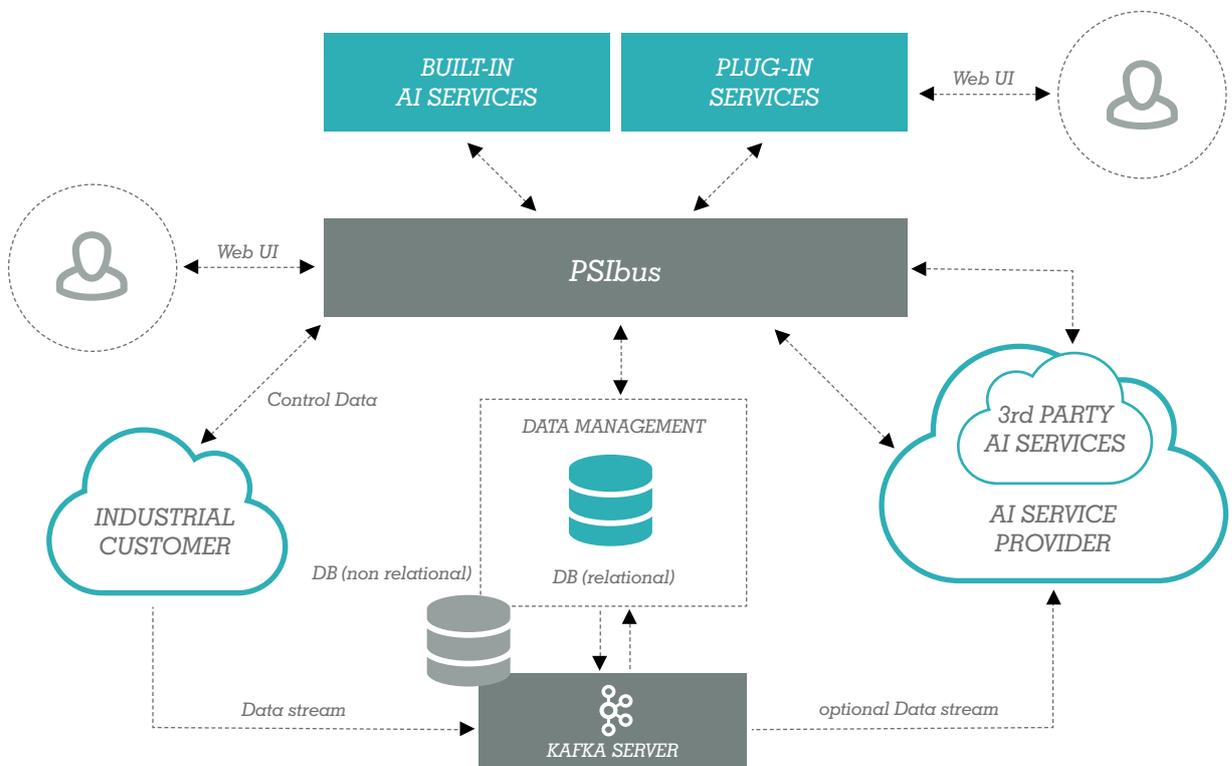


Abbildung 3: Architektur des KICA-IPK-Cloud-Service

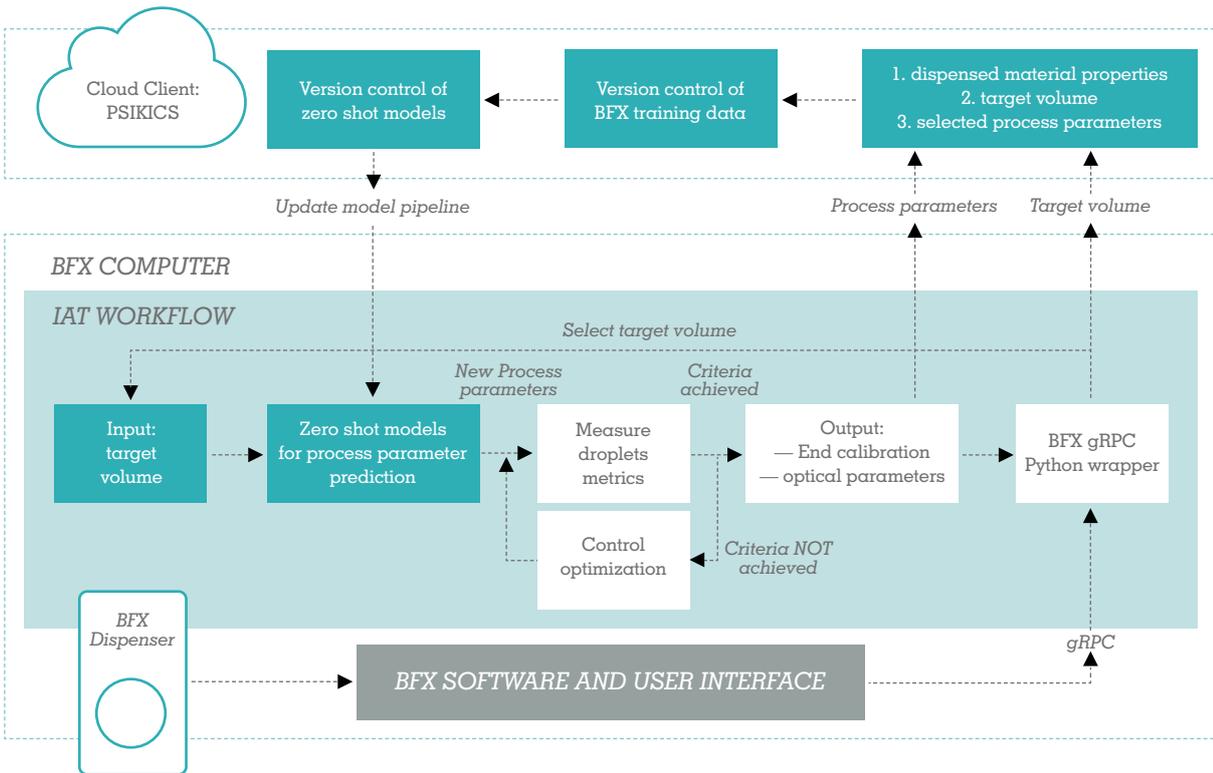


Abbildung 4: BioFluidix-System-Workflow

Diese Cloud-Server-Plattform basiert auf der PSImetals-Service-Plattform-Architektur, bei der die Daten zwischen den Partnern über SSL-verschlüsselte Kafka-Streams ausgetauscht werden. Benutzerzugriff auf den Server erfolgt über ein Webinterface zur Durchführung aller notwendigen Aktionen. Unterhalb der Weboberfläche befindet sich eine dockerisierte Microservice-Architektur, verwaltet von Kubernetes. Die interne Kommunikation zwischen den Services erfolgt über eine Busstruktur auf Basis des PSIBus.

Da größere Datenmengen verarbeitet werden müssen und die Leistung eine wichtige Rolle bei der Ausführung der KI-Dienste spielt, wird ein hybrider Datenbankansatz verwendet, bei dem nur minimale Daten in einer relationalen Datenbank gespeichert werden und der Großteil der Daten nichtrelational gespeichert wird (Data-Lake).

Die Cloud-Server-Plattform stellt eine Reihe von KI-Diensten im Zusammenhang mit maschinellem Lernen zur Verfügung, z. B. Mustererkennung auf

Videos und aufgezeichneten Datenströmen, Datenaugmentierung oder Labeling. Hierbei wird auf die Einbindung bereits etablierter Tools auf diesem Gebiet gesetzt. Das flexible Design der Plattform ermöglicht es Kunden und Anbietern, benötigte Dienste auszuwählen und auch eigene Dienste über eine definierte API entweder auf dem Server oder, über VPN-geschützt, aus der Ferne auf eigener Hardware einzubinden.

Volumenkontrolle

Nachdem eine Dosis vom Benutzer ausgewählt worden ist, wird ein entsprechendes Druckmuster gewählt, der BioFluidix-Nanoliter-Dispenser initialisiert und der Druck gestartet.

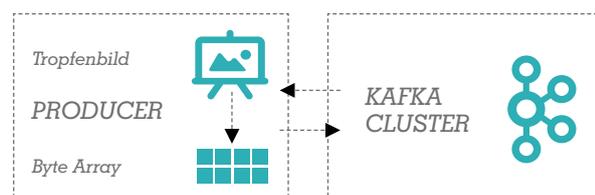


Abbildung 5

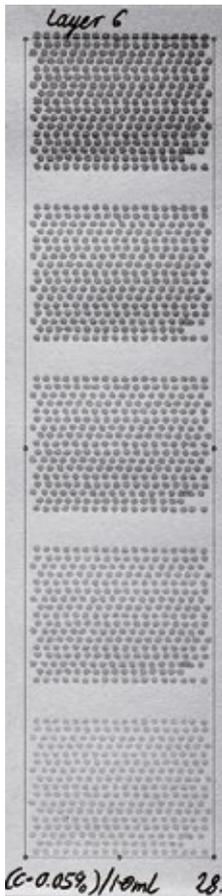


Abbildung 6

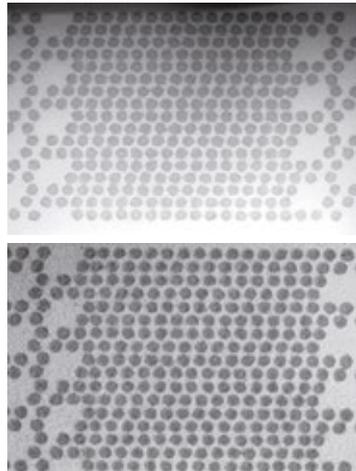


Abbildung 7: Schlechte und gute Ausleuchtung, unterschiedliche Farben

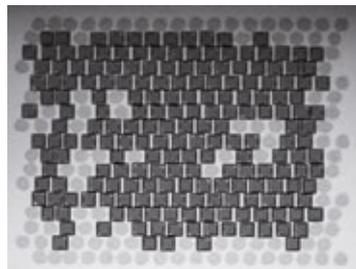


Abbildung 8: Tropfendetektion. Zur Illustration sind hier nicht alle Tropfen detektiert.

Der Workflow, wie abgebildet, umfasst die Eingabe des Zielvolumens, die Vorhersage der Prozessparameter, die Messung der Tropfenmetriken und die Prozessregelung. Das Diagramm zeigt die Interaktionen zwischen den verschiedenen Komponenten und Subsystemen des Systems, einschließlich Host-Computers, gRPC Python Wrapper, Software und Benutzeroberfläche von BioFluidix sowie des Cloud-Clients PSI KICS.

Die Besonderheit des Workflows ist die Mehrstufigkeit der KI-gestützten Analyse. Diese ist für einen Echtzeitprozess notwendig, ohne von Latenzen des Internets gebremst zu werden.

Die erste Stufe ist der cloudbasierte KI-Dienst PSI KICS zum Training und zur Etablierung von Tropfenerzeugungsmodellen. Mit geeigneten Trainingsdaten aus Zero-Shot-Modellen für unterschiedliche Materialien und Zielvolumina wird über eine versionierte Modell-Pipeline von IAT ein optimierter Parametersatz geliefert.

Die zweite Stufe ist die Prozessregelung in Echtzeit bei der Tropfenerzeugung entsprechend der Qualität der erzeugten Tropfen. Die BioFluidix-Steuersoftware (BFX-Client) erfragt via gRPC die geeigneten Parameter von der ersten Stufe und verwendet das erzeugte KI-Modell zur Optimierung der Tropfen. Da dieser Prozess zeitkritisch ist, muss die Ausführung selbst lokal erfolgen.

Ablauf der Datenübertragung für Identität und Qualität

Nach jeder produzierten Schicht wird ein Bild jedes der 15 ODFs aufgenommen. Diese Bilder werden via gRPC von einer Softwarekomponente „Producer“ an den KICS-Server gesendet, der die entsprechende Verarbeitung vornimmt. Dort werden diese in entsprechend trainierten Modellen verarbeitet und anhand vorgegebener Metriken durch KI Bewertungen zu den einzelnen Bildern erzeugt.

Der Drucker wiederum entscheidet anhand der zurückgegebenen Werte, ob der aktuelle Prozess gültig ist, und regelt oder unterbricht diesen bei Bedarf.

Identitätskontrolle

Die Wirkstoffe wurden jeweils unterschiedlich eingefärbt.



Da mit mehreren Wirkstoffen in verschiedenen Mustern auf ein IDF gedruckt werden kann, ist die Prüfung der Identität komplex.

Auftragungskontrolle

Für jedes einzelne Produkt wird jeweils pro Schicht ein Bild verarbeitet. Das KI-Modell zählt die in dieser Schicht dazugekommenen Tropfen.

Aufgrund unterschiedlicher Muster, Farben, Zieldosen und Tropfengrößen ergeben sich potenziell Millionen unterschiedlicher Druckbilder, die den Aufwand einer klassischen Detektion unverhältnismäßig macht. Eine KI kann dies leisten.

Die von Relimetrics entwickelte KI-gestützte Bewertung der gedruckten Tropfen erfolgt zweistufig. Zuerst werden die Tropfen auf dem ODF auf Basis eines YOLO-Modells detektiert. Da sich die Tropfen in der Regel nur in ihrer Farbsättigung entsprechend der Schicht unterscheiden, war eine Segmentierung und Klassifizierung auf Basis vorhandener Modelle nicht erfolgreich. Wesentlich für die Bewertung sind dabei gleichmäßige Ausleuchtung, Tiefenschärfe und ODF-Papierqualität, Farbdichte des Wirkstoffs, Trocknungszeit etc. zu legen.

Anhand der detektierten Tropfen wird ein 6-dimensionaler Feature-Vektor (RGB, mean, std) gebildet. Der SVM-Klassifikator erreichte Trainingsgenauigkeit von 98.2 % und eine Testgenauigkeit von 97.8 %.

Ergebnis

Eine KI-gestützte Volumenkontrolle erhöht die Abgabegenauigkeit und die Prozessstabilität. Die

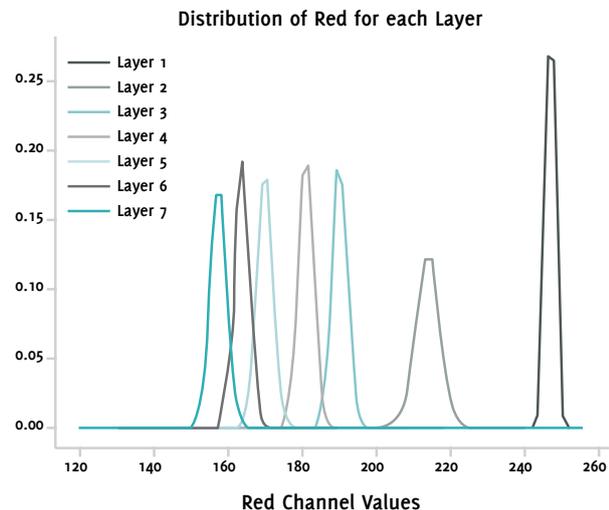
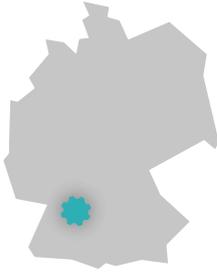


Abbildung 9: Rot-Komponente für die jeweilige Anzahl (Layer) übereinander gedruckter Tropfen

Effizient, Flexibilität und Skalierbarkeit können durch standardisierte Cloud-Dienste und Fernüberwachung erhöht werden, sichtbar insbesondere in der Versionsverwaltung von Trainingsmodellen. Die KI-basierte Identitäts- und Auftragungskontrolle funktioniert und erhöht signifikant die Sicherheit der Produkte.

Die Anforderung an den Ersatz der nasschemischen Analyse kann mithilfe der entwickelten KI-Kontrollen erfüllt werden. Zusätzlich verringert die KI-Unterstützung den Aufwand für Tinten- und Prozessentwicklung wesentlich.



ProKinect

KOLLABORATIVES CONDITION MONITORING

HERSTELLERÜBERGREIFENDE FEHLERDIAGNOSE VON WERKZEUGMASCHINEN

Wiebke Zenn (TRUMPF Werkzeugmaschinen SE & Co. KG), Sebastian Roeding (WITTENSTEIN SE), Andreas Friedmann (Fraunhofer LBF), Kamal Galrani (Tvarit GmbH)

Eine herstellerübergreifende Zustandsüberwachung ermöglicht eine effizientere und genauere Fehlerdiagnose und erhöht die Maschinenverfügbarkeit.

Die moderne Fertigungsindustrie steht vor ständigen Herausforderungen, wenn es darum geht, die Verfügbarkeit und Zuverlässigkeit von Produktionsmaschinen zu maximieren. Traditionelle Instandhaltungsstrategien stoßen oft an ihre Grenzen, insbesondere, wenn es darum geht, Qualitätsabweichungen im Fertigungsprozess, die durch beginnenden Verschleiß oder Fehlfunktionen verursacht werden, eindeutig zuzuordnen. Da Maschinen und Anlagen in der Produktion meist aus Komponenten verschiedener Zulieferer bestehen, ist eine tiefgreifende Expertise zum exakten Aufbau der Komponenten, zu deren Verhalten sowie zur Diagnose ihrer Zustände nicht in einer Firma allein verfügbar. Ein innovativer Ansatz, der in den letzten Jahren zunehmend an Bedeutung gewonnen hat, ist das Collaborative Condition Monitoring¹

Was ist Collaborative Condition Monitoring?

Collaborative Condition Monitoring (CCM) beschreibt eine automatisierte Zustandsüberwachung mit verteilten und unternehmensübergreifenden Diagnosesystemen. Das Besondere an diesem Ansatz

ist die Zusammenarbeit zwischen verschiedenen Akteuren - darunter Maschinenhersteller, Betreiber und Komponentenlieferanten -, die in einem gemeinsamen Datenraum agieren. Dieser gemeinsame Datenraum bildet eine technische Infrastruktur zur Aggregation und zum Austausch von Daten und Informationen über die verschiedenen Hierarchieebenen und ermöglicht die Nutzung von Daten aus verschiedenen Quellen, um einen umfassenden Überblick über den Maschinenzustand abzuleiten. Dafür bedarf es einer sicheren Datenspeicherung und Zugriffsberechtigungen, um sensible Daten zu schützen und kontrolliert zu teilen.

Aufbau einer herstellerübergreifenden Fehlerdiagnose

Grundlage für eine Zustandsüberwachung ist die Erfassung und Auswertung von Daten. Sensoren an der Maschine messen kontinuierlich Betriebsparameter wie Temperaturen und Drücke, aber auch hochfrequente Vibrationen, Ströme oder Drehzahlen. Die für eine Zustandsdiagnose benötigten Daten müssen von den Komponenten in geeignetem Format bereitgestellt werden. Diese werden dann beispielsweise von einem Edge-Device empfangen und mit einem gemeinsamen Zeitstempel versehen.

Für eine praxistaugliche Kollaboration mehrerer Unternehmen muss die Datenspeicherung sicher



und der Datenaustausch kontrollierbar sein. Hier arbeiten Projekte wie Catena-X an Möglichkeiten gemeinsamer sicherer Datenräume. Alternativ bieten sich Frameworks an wie die Python-Bibliothek PySyft Tools zur Organisation sensibler Daten und für den Datenaustausch über Zugriffsberechtigungen. Eine darauf aufbauende Methode ist das Federated Learning, welches das Trainieren von Modellen ohne direkten Zugriff auf die Rohdaten ermöglicht und dadurch ein wichtiges Werkzeug in der herstellerübergreifenden Zusammenarbeit ist. Sind diese technischen Voraussetzungen gegeben, können neue kooperative Diagnosen entwickelt werden. Die Kooperation kann dabei auf drei Ebenen stattfinden. Die Partner können sich gegenseitig Rohdaten zur Verfügung stellen, die dem anderen bisher nicht zugänglich waren. Es können bereits aus den Rohdaten extrahierte Features bereitgestellt werden. Dadurch wird das Verständnis eines Herstellers über die eigenen Daten genutzt und nur die relevanten Informationen weitergegeben. Eine dritte Kooperationsebene ist das Teilen von reinen Zustandsinformationen. Die Partner führen unabhängig ihre Diagnosen durch und nur die Ergebnisse werden zusammengetragen. So werden die eigenen Daten maximal geschützt, während dennoch das Zusammenführen der Zustandsinformationen einen ganzheitlicheren Überblick und eine effizientere Differenzialdiagnose ermöglicht.

Umsetzung am Beispiel einer 2D-Laserschneidmaschine

Am Beispiel einer 2D-Laserschneidmaschine wurde im Rahmen des BMBF-Verbundprojekts „ProKInect“ ein solches kollaboratives Zustandsüberwachungssystem implementiert, skizziert in Bild 1. Ziel war es, basierend auf einer kooperativen Auswertung anfänglich fragmentierter und proprietärer Betriebsdaten einer Laserschneidmaschine der Firma TRUMPF und eines sensorbestückten Planetengetriebes der Firma WITTENSTEIN die Positionierachsen der Werkzeugmaschine zu überwachen und Ausfallwahrscheinlichkeiten des Gesamtsystems vorherzusagen.

Eine von TRUMPF entwickelte Hardware wurde genutzt, um Maschinendaten (Motorströme und Drehzahlen) und Getriebedaten (Vibrationen und Temperaturen) hochabgetastet und zeitsynchron zu erfassen. Anschließend wurden diese an einen maschinennahen Server weitergeleitet und dort in Datenbanken abgelegt. Hier hat die Firma TVARIT eine sichere Datenverwaltung mit der Python-Erweiterung PySyft umgesetzt, indem sie herstellereigene Domänen und kontrollierbare Zugriffsberechtigungen implementiert hat.

Basierend auf geteilten Rohdaten und extrahierten Features wurden daten- und modellbasierte Algorithmen zur Erkennung von Fehlerzuständen

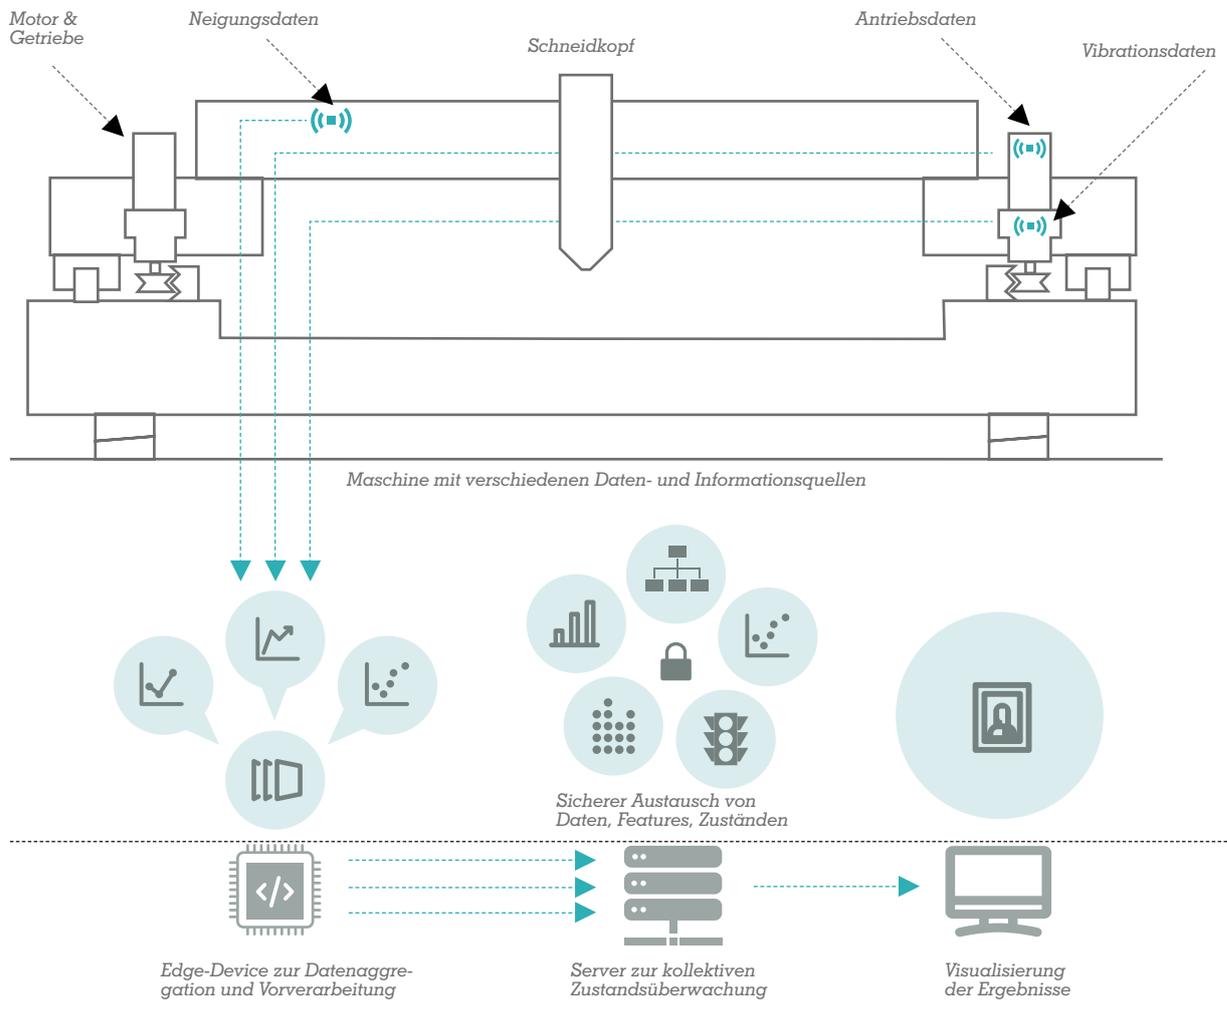


Abbildung 1: Aufbau der herstellerübergreifenden Fehlerdiagnose im Projekt ProKInect

wie Ritzelverschleiß, Umkehrspiel und fehlerhafter Neigung der Maschine entwickelt.

Über wissensbasierte Modelle, entwickelt vom Fraunhofer LBF, wurden die Ergebnisse der einzelnen Zustandsüberwachungen zusammengeführt und dem Nutzenden in Form einer Fehlerursachenanalyse sowie einer Vorhersage von Ausfallwahrscheinlichkeiten des Gesamtsystems bereitgestellt.

Nutzen des kollaborativen Zustandsmonitorings

Das kollaborative Zustandsmonitoring bietet eine Reihe von Vorteilen gegenüber traditionellen Wartungsansätzen. Einer der wichtigsten Vorteile ist die effizientere und ganzheitlichere Fehlerdiagnose.

Interaktionen und gegenseitige Beeinflussungen der Komponentenzustände werden berücksichtigt und in die Diagnose der Gesamtmaschine integriert. Auftretende Qualitätsabweichungen im Fertigungsprozess können direkt auf die ursächliche Komponente zurückverfolgt werden. Die Zielgruppe hierfür ist das Wartungspersonal. Ein modernes Assistenzsystem, das die Diagnoseergebnisse aller Komponenten vereinheitlicht, unterstützt den Techniker dabei, gezielte Maßnahmen zu ergreifen und so die Maschinenverfügbarkeit zu maximieren.

Ebenso profitieren auch die Maschinen- und Komponentenhersteller von der Kollaboration. Die



geteilten Daten ermöglichen eine Performanceanalyse der eigenen Produkte und der eingesetzten Komponenten. Auf dieser Basis können die Komponenten besser dem spezifischen Nutzen angepasst werden, Optimierungen vorgenommen und neue Dienstleistungen entwickelt werden.

Herausforderungen und Zukunftsperspektiven

Trotz der vielen Vorteile gibt es auch Herausforderungen bei der Implementierung von kollaborativer Zustandsüberwachung. Eine der größten Herausforderungen ist die Integration der verschiedenen Datenquellen und die Sicherstellung der Datenqualität. Es benötigt weitreichende Standards, um die Konnektivität zwischen Komponenten und Maschinen effektiv herzustellen. Zudem ist wichtig, dass die erfassten Daten zuverlässig und verständlich sind, um aussagekräftige Analysen und Vorhersagen zu ermöglichen.

Ein weiteres Hindernis ist die Akzeptanz der neuen Technologien durch die Nutzenden. Es ist entscheidend, dass die einzelnen Partner Vertrauen in die Mechanismen des Datenteilens und die Ergebnisse der Zustandsüberwachung haben. Dies kann durch transparente und erklärbare KI-Modelle erreicht werden, die die Entscheidungen und Vorhersagen nachvollziehbar machen. Auch der Nutzen muss für jeden Partner deutlich werden. Durch entsprechen-

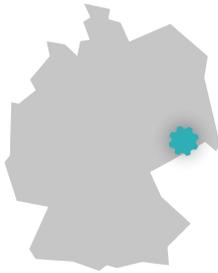
de Geschäftsmodelle muss ein Anreiz geschaffen werden, sich an einem solchen Datenökosystem zu beteiligen.

In Zukunft werden das kollaborative Diagnosemethoden weiter an Bedeutung gewinnen. Die fortschreitende Digitalisierung und Vernetzung von Maschinen und Anlagen wird die Datenverfügbarkeit und -qualität weiter verbessern. Es kommen zunehmend Komponenten auf den Markt, die bereits IIoT-Fähigkeiten aufweisen. Darüber hinaus wird die Integration von Cloud- und Edge-Computing-Technologien die Datenverarbeitung und -analyse beschleunigen und effizienter gestalten.

Projekte wie „ProKInect“ zeigen, wie kollaborative Zustandsüberwachung erfolgreich umgesetzt werden kann und welche Vorteile es für die Fertigungsindustrie bietet. Trotz der bestehenden Herausforderungen bietet diese Technologie vielversprechende Perspektiven für die Zukunft der industriellen Wartung und Überwachung.

1) Plattform Industrie 4.0: Kollaborative datenbasierte Geschäftsmodelle. Collaborative Condition Monitoring – Wie durch unternehmensübergreifende Kollaboration Mehrwert generiert werden kann. Berlin, 2020.

Plattform Industrie 4.0: Kollaborative datenbasierte Geschäftsmodelle (plattform-i40.de)



MIT OPC UA ZUR INTELLIGENTEN FERTIGUNG: KI-ANWENDUNGEN EINFACH ENTWICKELN UND SKALIEREN

Carl Willy Mehling, Christian Keilig, Sven Pieper (Fraunhofer IWU); Alexander Wand, Christian Röder (SEITEC GmbH)

Mit OPC UA können KI-Lösungen einfach auf neue Maschinen übertragen werden und ihr volles Wertschöpfungspotenzial auf dem Shopfloor entfalten.

Künstliche Intelligenz (KI) kann enormes Innovationspotenzial auf dem Shopfloor entfalten. Voraussetzung hierfür sind wertschöpfende Use-Cases und dazu passende Maschinendaten in hoher Qualität. Während es meist viele Ideen für Use-Cases gibt, ist die Datenerfassung (DAQ) oft sehr aufwendig.

Automatisierungs- und Entwicklungsteams müssen sich abstimmen, um relevante Maschinendaten zu identifizieren und ein gemeinsames Verständnis zu erarbeiten. Anschließend können Zugriffe auf das Maschinennetz und die Steuerung eingerichtet und die ausgewählten Variablen in der Steuerung lokalisiert werden. Für einzelne Maschinen können so Prototypen der KI-Anwendung entwickelt und evaluiert werden. Auch wenn Prototypen klare Mehrwerte demonstrieren, scheitert die Skalierung auf weitere Maschinen oft am hohen Zeit- und Arbeitsaufwand. Innovationen scheitern damit durch die ausbleibende breite Verbreitung der Anwendung auf dem Shopfloor.

Der hohe Zeit- und Arbeitsaufwand für die Übertragung von Use-Cases auf weitere Maschinen liegt an der Individualität der Maschinen und daraus entste-

henden Einzellösungen der DAQ für verschiedene Use-Cases und Maschinen. Jede Maschine erfordert eine erneute Konnektierung der relevanten Variablen. Entstehende Verbindungen sind damit auf einen spezifischen Anwendungsfall zugeschnitten. Eine Mehrfachnutzung der Daten durch andere Use-Cases ist häufig nicht vorgesehen, wodurch kaum Synergien in der Datenerfassung entstehen.

Hier setzt OPC UA an. Es beschleunigt die Entwicklung und Skalierung von Anwendungen, indem Variablen einheitlich über viele Maschinen hinweg zur Verfügung gestellt und von allen Use-Cases genutzt werden können. OPC UA schließt die Lücke zwischen Prototyp und breiter Anwendung auf dem Shopfloor und sorgt somit für eine gesteigerte Wertschöpfung.

Im Artikel werden die wichtigsten Komponenten von OPC UA für die einfache Entwicklung und Skalierung von KI-Anwendungen erläutert und deren Anwendung anhand des KausalAssist-Forschungsprojektes illustriert.

OPC UA – WAS IST DAS?

OPC UA (Open Platform Communications Unified Architecture) ist ein plattformübergreifender Standard für die industrielle Kommunikation. OPC UA verbindet IT und OT durch standardisierte Strukturierung, Bedeutung und Übertragungsformate von Daten. Dabei ist OPC UA kein Protokoll, sondern eine Sammlung interoperabler und kombinierbarer Komponenten.



Die Kernkomponenten beantworten u. a. diese Fragen:

- **Informationsmodell:** Was bedeuten die Variablen und in welchem Kontext stehen sie?
- **Kommunikationsmodell:** Wann werden Informationen ausgetauscht?
- **Protokolle:** Welches der vorhandenen Protokolle soll für den Austausch verwendet werden?
- **Security:** Wer darf auf die Informationen zugreifen und wie werden sie geschützt?

OPC UA ermöglicht damit Interoperabilität, ist für eine Vielzahl von Steuerungen verfügbar und erleichtert so die Integration und Skalierung von wertschöpfenden Anwendungen in der Industrie.

KI auf dem Shopfloor skalieren mit OPC UA

OPC UA beschleunigt die Einführung von KI auf dem Shopfloor hauptsächlich durch zwei Elemente: Ein gemeinsames Informationsmodell, das ein einheitliches Interface zu Maschinendaten für alle IT- und OT-Anwendungen bereitstellt, und einen OPC-UA-Aggregationsserver, der die notwendige Infrastruktur bietet, um Maschinendaten an zahlreiche Anwendungen weiterzugeben.

OPC UA als einheitliche Schnittstelle

Ein OPC-UA-Informationsmodell definiert Variablen- und Objekttypen sowie ihre Bedeutung. Dieses Modell dient als Blaupause, um Informationen mit derselben Bedeutung auf allen Maschinen einheitlich darzustellen. Für viele Domänen gibt es bereits standardisierte Informationsmodelle (Companion Specifications), die im eigenen Unternehmen verwendet und erweitert (Enterprise Specification) werden können. Durch die Anwendung der Informationsmodelle auf die Maschine entsteht eine einheitliche Schnittstelle und Anwendungen können einfach auf weitere Maschinen übertragen sowie neue Anwendungen schnell unter Nutzung der bestehenden Datenanbindung entwickelt werden.

Aggregationsserver als zentraler Zugangspunkt

Um Maschinenvariablen effizient für viele Anwendungen nutzbar zu machen, ist die richtige Infrastruktur entscheidend. Ein OPC-UA-Aggregationsserver spielt dabei eine zentrale Rolle. Er verbindet sich mit allen OPC-UA-Servern der Steuerungen und vereint deren Informationsmodelle. Dieser aggregierte OPC-UA-Server ist für die Datenbereitstellung an viele Clients konzipiert und verteilt die Informationen, ohne die Steuerungen zusätzlich zu belasten.

Als gesicherter, zentralisierter Zugangspunkt vereinfacht der Aggregationsserver Firewall-Regeln, verbessert die Netzwerksicherheit und erleichtert das Onboarding von IT-Systemen und Produktionsanlagen. Zudem harmonisiert er verschiedene Informationsmodelle, um eine standardisierte Schnittstelle für alle IT-Systeme zu gewährleisten.

Anwendungsbeispiel: KausalAssist-Projekt

Im Forschungsprojekt KausalAssist wird ein KI-Assistenzsystem zur schnellen Behebung von ungeplanten Stillständen entwickelt (siehe Kapitel „KI-Methoden“). Für die Softwaremanagement-Applikation und die KI-Komponenten werden Live-Maschinendaten von sieben Steuerungen (vier verschiedene Modellreihen: Simatik S7-1500, Sinumerik 840dsl, Sinumerik One, Beckhoff TwinCAT 3) verwendet.

Auf allen genannten Steuerungen konnte mit geringem Aufwand ein OPC-UA-Server aktiviert werden. Ein einheitliches Informationsmodell, entwickelt vom Fraunhofer IWU, wurde auf den verschiedenen Steuerungen ausgerollt, um eine standardisierte Schnittstelle für die Softwareanwendungen zu schaffen. Dieses Informationsmodell nutzt u. a. die Companion Specification UA for Machine Tools und wurde um eine einheitliche Darstellung relevanter Auftragsdaten ergänzt. Steuerungsinterne Variablen wurden auf dieses Modell gemappt und weitere maschinenspezifische

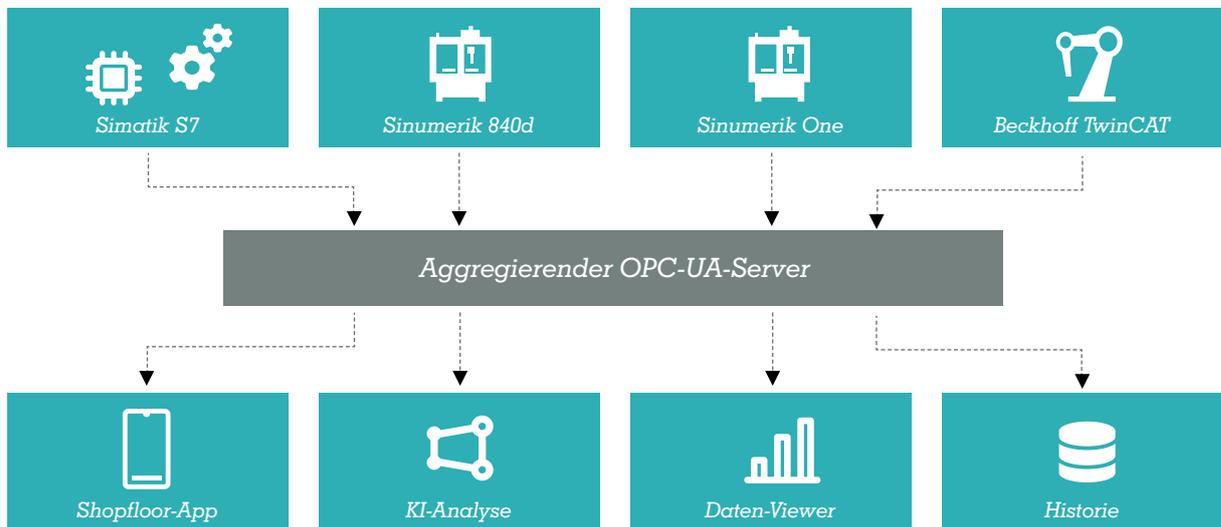


Abb. 1: OPC-UA-basierte Dateninfrastruktur für die einfache Nutzung von Maschinenvariablen durch KI und Software im KausaLAssist-Projekt.

Variablen über das Standard-OPC-UA-Mapping der Steuerungshersteller eingebunden.

Die Softwarekomponenten werten alle aktuellen Störungsmeldungen, Maschinenzustände und Auftragsdaten für ein effektives Störungsmanagement aus. Das Erlernen der KI-Komponenten benötigt zusätzlich Aufzeichnungen dieser Daten.

Der vom Projektpartner SEITEC GmbH entwickelte Aggregationsserver stellt all diese Variablen und Meldungen auf einem gemeinsamen OPC-UA-Server dar. Darüber hinaus speichert der Server ein Systemabbild aller Variablen für die letzten zehn Minuten (frei konfigurierbar). Bei einem ungeplanten Stillstand wird dieses Systemabbild gemeinsam mit allen aufgetretenen Fehlern dauerhaft gespeichert und von der KI zur Fehlerdiagnose verwendet. Dieses Systemabbild kann bei schwerwiegenden Störungen mit dem Hersteller geteilt werden. Ein speziell dafür entwickeltes Visualisierungstool ermöglicht eine einfache Analyse aller Variablen und ihre zeitlichen Verläufe.

Fazit

Der Einsatz von OPC UA ermöglicht eine effiziente und übertragbare Implementierung von KI-Lösungen auf dem Shopfloor. Durch einheitliche Informationsmodelle und einen Aggregationsserver werden Maschinendaten zentral zugänglich gemacht und die Übertragung von Anwendungen auf verschiedene Maschinen erheblich vereinfacht. Dies reduziert den aktuell hohen Zeit- und Arbeitsaufwand für die Maschinenanbindung, der in der Individualität der Maschinen und den vielen Einzellösungen zur Datenakquise begründet liegt. Das Anwendungsbeispiel im KausaLAssist-Projekt zeigt praxisnah, wie OPC UA zur schnellen Behebung von ungeplanten Stillständen beiträgt und als ideale Datengrundlage für die KI-Komponenten dient. Die Dateninfrastruktur wurde im Projekt bei drei produzierenden Unternehmen getestet und dank OPC UA in wenigen Stunden am jeweiligen Standort eingerichtet. Aufgrund der vielversprechenden Resultate im Projekt werden die Softwarekomponenten und Strategien für den Aufbau der OPC-UA-Infrastruktur weiterentwickelt und von der SEITEC GmbH und dem Fraunhofer IWU für interessierte Firmen bereitgestellt.



TransKI

BEFÄHIGUNG VON WERKZEUGMASCHINEN FÜR EINE MACHINE-LEARNING-BASIERTE WERKZEUGÜBERWACHUNG

Maximilian Berndt, Prof. Dr.-Ing. Jan C. Aurich (Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau, Lehrstuhl für Fertigungstechnik und Betriebsorganisation)

Tim Reeber, Univ.-Prof. Dr.-Ing. Dr. h. c. Hans-Christian Möhring (Universität Stuttgart, Institut für Werkzeugmaschinen)

Mit einem minimalinvasiven Eingriff kann jede Werkzeugmaschine industriell skalierbar mit einem Machine-Learning-basierten Werkzeugüberwachungssystem ausgestattet werden.

Die Industrie 4.0 steht für eine neue Ära der Fertigungstechnik, in der digitale Technologien und Vernetzung die Produktionsprozesse grundlegend verändern. Durch die Integration von cyber-physischen Systemen, dem Internet der Dinge und fortschrittlicher Datenanalyse entstehen intelligente Fabriken, die effizient, flexibel und anpassungsfähig sind. Diese Entwicklungen ermöglichen eine präzise Überwachung und Steuerung der Produktion, wodurch die Produktivität und Qualität gesteigert sowie die Betriebskosten gesenkt werden. Im Kontext der Fertigungstechnik gewinnt daher eine fortschrittliche Maschinen- und Prozessüberwachung zunehmend an Bedeutung.

Die meisten Maschinen sind jedoch nicht ausreichend für die Integration in das System Industrie 4.0 ausgestattet. Dabei können Maschinen durch den Einsatz von Messtechnik bereits heute kostengünstig für die Integration in die Industrie 4.0 vorbereitet werden. Dies bedeutet, dass Maschinen nicht nur in der Lage sind, ihren eigenen Zustand kontinuierlich zu überwachen, sondern auch Produktionsprozesse durch

vorausschauendes Monitoring und durch Prognosen effizienter und kostengünstiger zu gestalten. In der Fertigungstechnik eröffnet dies völlig neue Möglichkeiten, die Produktivität zu steigern sowie Fertigungskosten zu reduzieren.

Die Ausstattung von Werkzeugmaschinen mit Sensorik ist dabei von grundlegender Bedeutung. Durch die Ausstattung von Werkzeugmaschinen mit Sensoren können Daten erfasst werden, die eine detaillierte Überwachung und Analyse der Maschine, aber auch des einzelnen Werkzeugs ermöglichen. Diese Daten bilden die Grundlage für eine ML-basierte Maschinenüberwachung. Die benötigte Sensorik, wie z. B. Kraft-, Schwingungs- oder Stromsensoren, ist dabei abhängig von dem angestrebten Anwendungsfall, den Investitionskosten und der eingesetzten Werkzeugmaschine.

Großes Potenzial bietet dabei eine Machine-Learning (ML)-basierte Werkzeugüberwachung von Fertigungsprozessen. Durch die kontinuierliche Überwachung des Zustands und der Leistung von Werkzeugen lassen sich Verschleiß und Beschädigungen frühzeitig erkennen, wodurch ungeplante Ausfallzeiten minimiert und die Einsatzzeit der Werkzeuge maximiert werden können. In einer zunehmend digitalisierten und vernetzten Produktionsumgebung stellt die Werkzeugüberwachung damit einen zentralen Baustein für die Umsetzung der Industrie 4.0 dar.

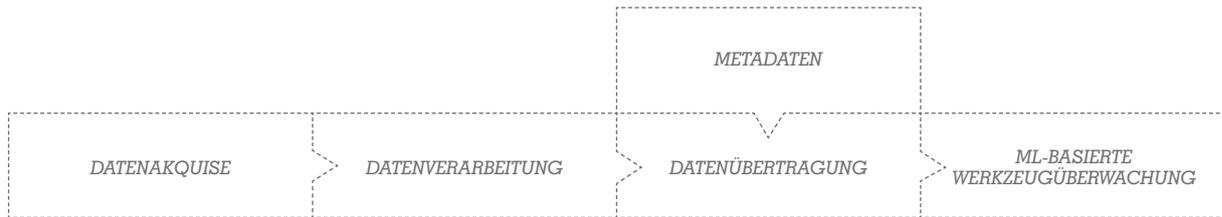


Abbildung 1: Prinzipskizze zur ML-basierten Werkzeugüberwachung einer Werkzeugmaschine

Methodik zur skalierbaren ML-basierten Werkzeugüberwachung

Die Integration von Sensoren zur Strommessung in Werkzeugmaschinen ermöglicht eine ML-basierte Werkzeugüberwachung. Damit kann der Werkzeugzustand überwacht und das Standzeitende prognostiziert werden. Wie in Abbildung 1 dargestellt kann für jede Werkzeugmaschine in vier Schritten eine Datenpipeline aufgebaut werden, die skalierbar in ein industrielles Umfeld integrierbar ist. Die Datenpipeline besteht dabei aus der Datenerfassung, der Datenverarbeitung, der Metadatengenerierung und der Datenübertragung. Im Folgenden werden die vier Schritte und die spezifischen Technologien und Softwarearchitekturen erläutert und erklärt wie diese in bestehende Systeme integriert werden können. So wurde im Projekt TransKI eine standardisierte Datenpipeline geschaffen, um Messdaten von unterschiedlichen Maschinen zu vereinheitlichen und zentral auf einer übergeordneten Computing-Architektur zu verarbeiten. Konzeptionell wird dabei jede Maschine als eigenständige Einheit betrachtet, in der die Daten verschiedener Maschineneinheiten über eine standardisierte Schnittstelle in der Computing-Architektur zusammenlaufen.

Datenakquise

In Werkzeugmaschinen können verschiedene prozessrelevante Größen erfasst werden, um den Fertigungsprozess zu überwachen. Eine kostengünstige und minimalinvasive Möglichkeit ist die Messung der Motor- und Achsströme. Dabei können zwei Quellen

genutzt werden, die Motorströme aus der Steuerung und die mit Stromwandlern gemessenen Ströme der Achsmotoren.

Moderne Werkzeugmaschinen verfügen häufig über die Möglichkeit, steuerungsinterne Daten aus der SPS oder NC auszugeben. Aufgrund der Heterogenität der Maschinen- und Steuerungshersteller ist die Formalisierung und Nutzung der steuerungsinternen Daten für die ML-basierte Werkzeugüberwachung jedoch auf individuelle Lösungen der Datenverarbeitung angewiesen. Zudem ist der Zugriff auf Steuerungsdaten nur bei einem geringen Anteil der im Einsatz befindlichen Maschinen gegeben.

Um auch an älteren Werkzeugmaschinen ohne Zugriff auf steuerungsinterne Daten prozessrelevante Messdaten erfassen zu können, kann durch die Nachrüstung von Retrofit-Messtechnik in die bestehende Maschineninfrastruktur die Erfassung von Motorströmen ermöglicht werden. Die Retrofit-Lösung besteht dabei aus Hall-Effekt-Stromwandlern, die galvanisch getrennt von der Leistungselektronik an den Phasen der Achsmotoren angebracht werden können. Pro Achse werden zwei Wandler benötigt. Hinzu kommt eine Auswerte- und Verarbeitungselektronik, die die Signale der Sensoren aufbereitet und in ein einheitliches Format überführt.

Datenverarbeitung

Die von verschiedenen Quellen akquirierten Motorströme müssen formalisiert werden. Dies ist notwendig, da sonst die ML-Modelle zur Werkzeugüberwa-



chung nicht auf die Daten von verschiedenen Quellen angewendet werden können. Dazu wurde im Trans-KI-Projekt eine Methodik entwickelt, um die mit der Retrofit-Lösung erfassten hochfrequenten Rohdaten an die steuerungsinternen Daten anzugleichen. Durch die Formalisierung können Motorströme maschinen- und quellenunabhängig für eine zentrale Werkzeugüberwachung genutzt werden. Mit der Angleichung der hochfrequenten Rohsignale an die steuerungsinternen Daten reduziert sich zudem die zu übertragende Datenmenge. So wird der Netzwerkauslastung und der Bandbreitenbedarf reduziert, was eine industrielle Skalierbarkeit begünstigt.

Metadaten

Um die akquirierten Daten identifizieren und einem Prozess sowie Werkzeug zuordnen zu können, müssen die Daten mit Metadaten gelabelt werden. Ziel ist die eindeutige Zuweisung der Daten zu einem spezifischen Werkzeug, sodass Daten von mehreren Werkzeugen analysiert und klassifiziert werden können. Dazu enthält die Metanachricht als Mindestanforderung Informationen über eine Laufvariable zur Identifikation der durchgeführten Operationen pro Werkzeug und eine eindeutige Identifikationsnummer des Werkzeugs sowie der Maschine selbst. Zusätzlich können Informationen über den Prozess, wie z. B. Schnittparameter, übertragen werden. Perspektivisch können die Metadaten mit Daten aus CAD/CAM-Systemen angereichert werden.

Um die Operationen des Werkzeugs und verschiedene Werkzeuge voneinander zu trennen, können Informa-

tionen aus der Steuerung verwendet werden. Bei der Retrofit-Lösung ist durch fehlenden Steuerungszugriff keine Rückkopplung zum laufenden Prozess möglich, sodass durch Signale (z.B. M-Befehl) im NC-Code Informationen über das verwendete Werkzeug und den Ein- und Austritt des Werkzeugs übermittelt werden.

Datenübertragung

Um die akquirierten Messdaten von verschiedenen Maschinen für die ML-basierte Werkzeugüberwachung zentral nutzen zu können, ist ein standardisiertes Datenformat nötig. Für die Übertragung der Daten von der Maschine zu einer übergeordneten Computing-Architektur eignet sich das JSON-Datenformat, da es ein leichtgewichtiges Format ist, das den Speicher- und Bandbreitenbedarf minimiert. Das ist insbesondere bei Übertragung großer Datenmengen, wie Messdaten, entscheidend. Zudem ist JSON plattform- und sprachenunabhängig. So können die Messdaten in verschiedene Computing-Architekturen integriert werden.

Das Ende der maschinenseitigen Datenpipeline ist ein Client, um die Messdaten zu einer übergeordneten Computing-Architektur zu übertragen. Als Nachrichtenprotokoll eignet sich dabei MQTT (Message Queuing Telemetry Transport). Vorteilhaft für die Übertragung von Messdaten ist dabei die hohe Effizienz, niedrige Latenz und geringe Bandbreitennutzung. Zudem ist bei der Übertragung mit MQTT eine Datenpersistenz gegeben, wodurch Nachrichten auch bei Verbindungsunterbrechungen gespeichert und verzögert zugestellt werden.



Fazit

Die im TransKI-Projekt entwickelte Lösung zur Maschinenanbindung für eine ML-basierte Werkzeugüberwachung wurde vollständig vor dem Hintergrund der industriellen Skalierbarkeit entwickelt. Durch die Vereinheitlichung der Motorströme aus der Steuerung mit denen einer Retrofit-Lösung können Maschinen von verschiedenen Herstellern und unterschiedlichen Ausstattungen in ein zentral operierendes Werkzeugüberwachungssystem zusammengefasst werden (wie in Abbildung 2 dargestellt).

Die Datenverarbeitung reduziert die zu übertragende

Datenmenge auf ein für die ML-Modelle nötiges Minimum, um einen effizienten Datenverkehr und eine temporäre Persistierung der Messdaten zu ermöglichen. Mit einem einheitlichen Datenformat können die Messdaten von verschiedenen Maschinen auf einer zentralen Computing-Architektur gesammelt und ausgewertet werden. Mit der Reduzierung auf nur eine Datenschnittstelle pro Maschine ist die Computing-Architektur unabhängig von der Maschine und deren Standort. Perspektivisch können die Messdaten auch mit weiteren Sensordaten für weitere ML-basierte Maschinen- oder Prozessüberwachungen erweitert werden.

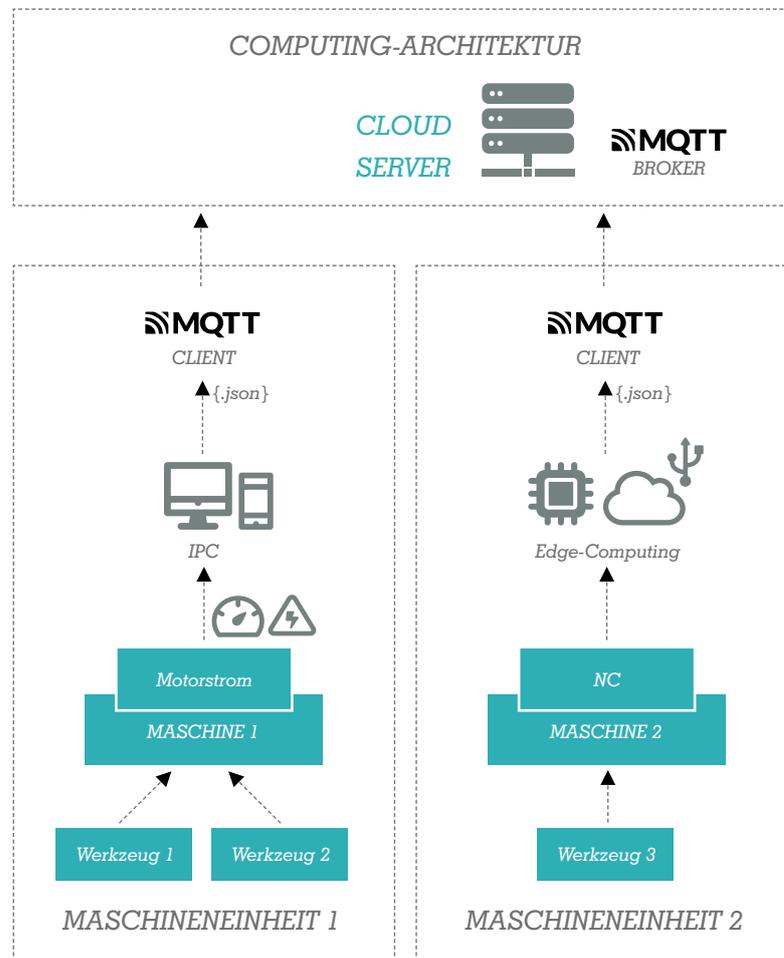
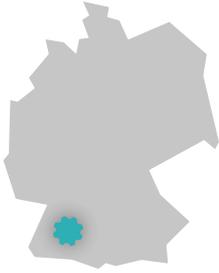


Abbildung 2: Anbindungskonzept für eine zentral operierende ML-basierte Werkzeugüberwachung



ECHTZEIT-PROZESS- ÜBERWACHUNG BEIM LASER BLANKING

Gerald Kolter, Dr. Frank Schneider (Fraunhofer-Institut für Lasertechnik)

Kontinuierliche Prozesse beim Laserstrahlschneiden erfordern eine sichere Erkennung der Prozessgrenze. Mit einer KI-basierten Echtzeitüberwachung können Sicherheitsreserven in der Geschwindigkeit kleiner bemessen und so die Produktivität gesteigert werden.

Das Laserschneiden von Platinen für die Automobilproduktion aus Coilmaterial, das Laser Blanking, ist im Vergleich zum Stanzen ein sehr effizientes Verfahren, um ressourcenschonend und flexibel zu produzieren. Die Gründe hierfür sind vielfältig: Zum einen entfällt die Notwendigkeit, für die Fertigung unterschiedlicher Platinen jeweils ein eigenes Werkzeug herzustellen sowie der Werkzeugwechsel, der bei einem Produktwechsel beim Stanzen erforderlich ist. Try-out-Fertigung entfällt, Prototypen und Konturoptimierungen für den nachfolgenden Umformprozess sind jederzeit möglich. Zum anderen kann der Verschnitt deutlich reduziert werden, da beim Laser Blanking nur ein minimaler Abstand zwischen den Bauteilen auf dem Coil eingehalten werden muss. Darüber hinaus bietet sich durch optimiertes Nesting, d. h. die Anordnung der Platinen auf dem Coil, die Möglichkeit, Verschnitt noch weiter erheblich zu reduzieren und flexibel verschiedene Platinen aus einem Band zu produzieren. Gerade bei kontinuierlich ablaufenden Prozessen wie dem Laser Blanking vom Coil ist eine hohe Zuverlässigkeit

unabhängig, da die Folgen eines unerkannten Schnittabbruchs und der damit verbundene Anlagenstillstand aufwendiger zu beheben sind als das Ausschleusen einzelner Fehlteile bei Einzelplatinen. Dies gilt auch für andere Anwendungen von der Rolle, wie z. B. die Herstellung von Bipolarplatten oder Batterieelektroden. Daraus ergibt sich für die Auslegung des Gesamtprozesses ein Zielkonflikt zwischen der Ausnutzung der maximalen Geschwindigkeit zur Erreichung der maximalen Produktivität einerseits und der Kalkulation von Sicherheitsreserven im Prozess zur Vermeidung von Stillständen andererseits.

Smarte Laseranlagen

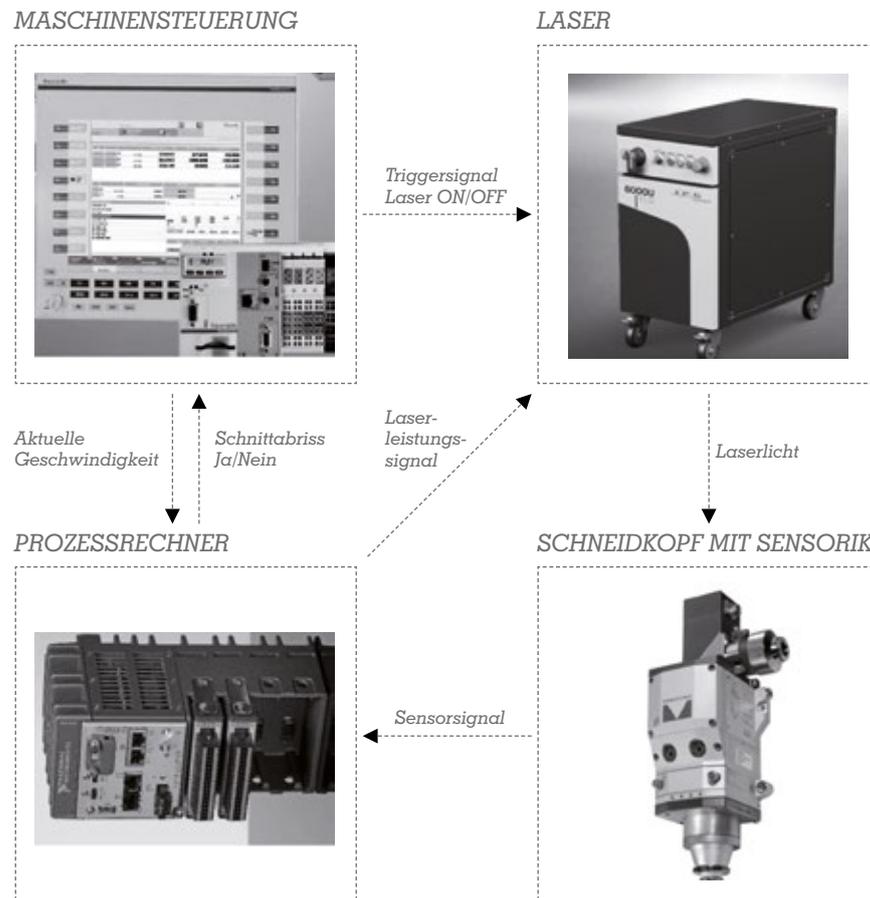
Um die beschriebenen Vorteile des Laser Blankings optimal nutzen zu können, wurde eine Demonstrator-Laser-Blanking-Anlage aufgebaut. Diese arbeitet im Gegensatz zu den sehr verbreiteten Flachbett-Schneidanlagen mit einem kontinuierlich durch die Anlage bewegten Coilmaterial. Dadurch kann durch den kontinuierlichen Bandvorschub im Vergleich zu einem Stop-and-Go-Betrieb zum einen die Produktivität gesteigert werden, zum anderen werden im Vergleich zu platinenweise zu bestückenden Flachbettmaschinen Beschränkungen der Platinengröße aufgehoben und der Verschnitt weiter reduziert, weil die Schachtelung kontinuierlich erfolgen kann und Restmaterial am Anfang und Ende von Einzelplatinen vermieden wird. Eine Skizze und die Realisierung der



Anlage ist in Abbildung 2.3 bzw. 2.4 dargestellt. Auf je einem Portal werden die beiden Laserschneidköpfe über den in großen Bereichen gemeinsamen Bearbeitungsraum von ca. 5,5 m x 1,6 m verfahren. Die Überlappung der Arbeitsbereiche ermöglicht dabei eine flexible Aufteilung der Schneidoperationen auf die beiden Schneidköpfe bei einer beherrschbaren Anlagenlänge. Unter den Laserschneidköpfen wird jeweils ein Schacht mitgeführt, der zum einen eine definierte Auflage für das Coilmaterial in unmittelbarer Nähe des Laserschneidprozesses bietet und zum anderen als Auffangbehälter für kleine Schrottteile dient, wie sie beim Schneiden von Löchern oder anderen kleinen Innenkonturen anfallen. Der Schacht ist außerdem an die Absaugung angeschlossen, sodass die Absaugung direkt unter dem Laserschneidprozess erfolgt und

somit die Staubbelastung in der Laserschutzkabine minimiert wird. Laser, Kühler, Absaugung und Schneidgas im Flaschenbündel befinden sich außerhalb der Laserschutzkabine und sind über Lichtwellenleiter und Rohrleitungen entsprechend verbunden. Im Schneidkopf reflektiert ein dichroitischer Spiegel das Prozesslicht auf zwei Photodioden, von denen die eine im sichtbaren Wellenlängenbereich sensitiv ist, die andere im nahen Infrarot. Der Spiegel ist für die Laserstrahlung, die vom Faserende des Lasers durch die Optik zur Bearbeitungszone auf dem Blech geführt wird, transparent, und reflektiv für die vom Prozess emittierte Wärmestrahlung des vom Laserstrahl aufgeschmolzenen Materials. Vorteile dieser koaxialen Anordnung ist zum einen die Richtungsunabhängigkeit bei der Erfassung der Prozessstrahlung und zum

Abbildung 1





anderen Justageunempfindlichkeit und Entfall von prozessnahen Störkonturen. Ziel der Erfassung und Auswertung des Signals dieser Photodioden ist es, den Zustand des Schneidprozesses zu erkennen. Insbesondere sollen Schnittabbrüche frühzeitig erkannt und damit deren Auswirkungen auf die Stillstandszeiten der Anlage und die Produktivität minimiert werden. Um eine ausreichend schnelle Auswertung der Photodiodensignale für den Hochgeschwindigkeitsschneidprozess zu gewährleisten, wird ein Prozessor mit FPGA eingesetzt. Mit diesem wird eine Zykluszeit für Vorverarbeitung und Inferenz von 2 Millisekunden erreicht, während die Datenerfassung parallel mit einer 100-fach kürzeren Zykluszeit läuft. In Abbildung 1 ist eine schematische Darstellung des Zusammenspiels der Komponenten gezeigt.

Minimal Invasive Leistungsmodulation (MILM): Ein perfekter Partner für KI

Entscheidend für eine zuverlässige Inferenz ist eine hohe Datenqualität, die anhand charakteristischer Merkmale in den Photodiodensignalen eine sichere Erkennung nicht vollständig getrennten Materials liefert. Ab wenigen Millimetern Blechdicke ist bereits die absolute Signalhöhe ein guter Indikator für den Wechsel von einem stabilen Schneidprozess mit einer ausgebildeten Schnittfuge zu einem eher einem Schweißprozess ähnlichem Zustand, bei dem keine offene Fuge ausgebildet wird. In diesem Fehlerzustand wird Material zur Blechoberseite ausgetrieben und in der Regel bildet sich ein intensives Plasma, dessen starke Emission sich deutlich von der thermischen

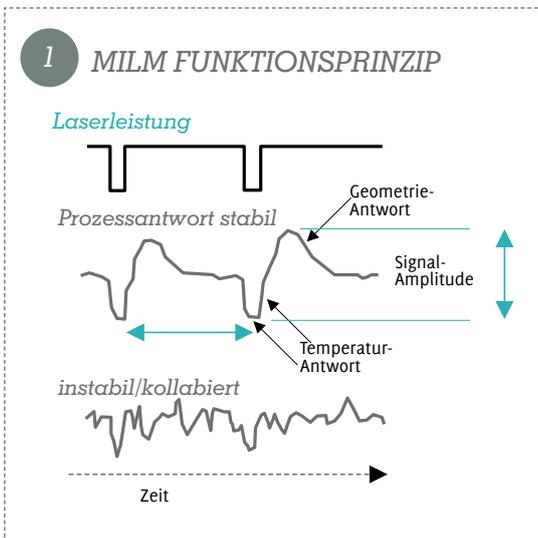
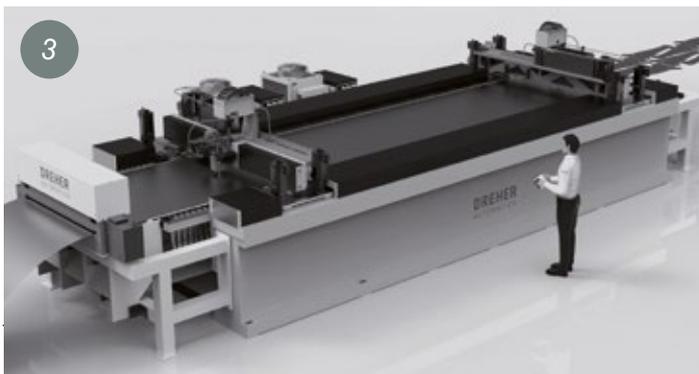
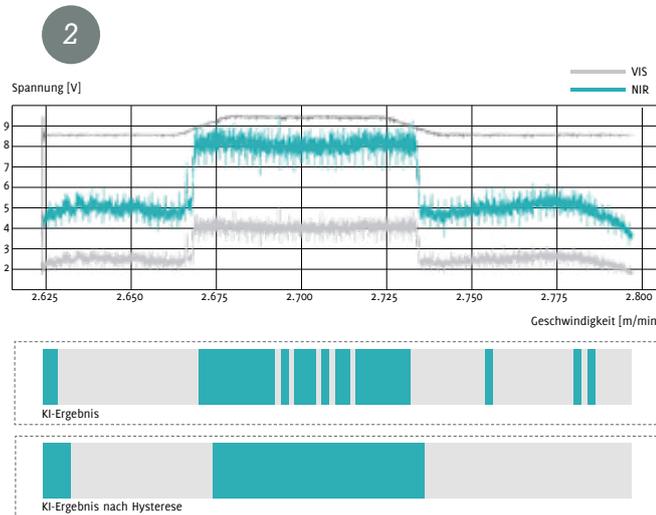


Abbildung 2





Strahlung bei einem regulären Schnitt unterscheidet. Bei dünnen Blechen führen bei Einsatz von Lasern im Multikilowattbereich die hohen Schneidgeschwindigkeiten bis über 100 m/min zu sehr hohen Temperaturen in der Wechselwirkungszone auf der Schneidfront, die Schneidfront wird flacher und damit aus der koaxialen Sicht der Photodiode besser zu beobachten und der Anteil von heißem, verdampftem Material steigt. All dies führt zu hohen Photodiodensignalen, die sich nicht signifikant von denen bei einem Schnittabbriss unterscheiden. Bereits übliche Schwankungen von der Fokusslage, des Düsenabstands und die konturabhängige Variation der Vorschubgeschwindigkeit können zu Signaländerungen führen, die in der gleichen Größe wie bei einem Schnittabbriss liegen.

Aus diesem Grund wurde die Minimal Invasive Laserleistungsmodulation (MILM) zur Prozessüberwachung beim Laserschneiden von Dünnscheiben entwickelt. Das Prinzip ist in Abbildung 2.1 dargestellt: Die Laserleistung wird für kurze Zeit, in der Größenordnung von 100 - 200 μ s, auf 50 - 80 % der maximalen Leistung reduziert. Die Antwort des Schneidprozesses ist ein charakteristisches, gut interpretierbares Signal, aus dem der Zustand des Schneidprozesses erkannt werden kann. Diese Reaktion besteht aus einem Abfall des Photodiodensignals, der durch die Abkühlung des Schneidprozesses aufgrund der reduzierten Leistung verursacht wird. Der anschließende Peak im Photodiodensignal entsteht durch den Temperaturanstieg bei Erhöhung der Laserleistung. Anschließend relaxiert der Prozess wieder auf die sich quasistationär einstellenden Verhältnisse. Dieser charakteristische Verlauf stellt sich nur bei einem stabil laufenden Schneidprozess ein. Bei einem Schnittabbriss ist nach der Modulation zwar der temperaturabhängige Abfall des Signals zu beobachten, der von der Geometrie der Schneidfront abhängige Peak bleibt jedoch aus. Auf diese Weise wird ein Schnittbruch detektiert. Die beschriebenen Effekte treten jeweils relativ zum quasistationären Schneidprozess mit konstanter, unmodulierter Leistung auf, daher sind die Antwortsignale unabhängig

von der absoluten Höhe des Photodiodensignals interpretierbar. Die Relaxation des Schneidprozesses nach der Leistungsmodulation erlaubt Zykluszeiten von 2 ms und teilweise weniger, die für eine Überprüfung des Schneidzustandes erforderlich sind. Die Zykluszeit sollte so kurz wie möglich gewählt werden, um eine schnelle Reaktion zu ermöglichen, andererseits aber ausreichend lang sein, um eine eindeutige Beurteilung des Erreichens des quasistationären Zustands sicherzustellen, bei einer typischen Abtastrate von 50 kHz und einer Zykluszeit von 2 ms ergibt sich so eine kurze Zeitreihe von 100 Messwerten zur Auswertung hinsichtlich des Schneidzustandes. Diese Zykluszeit ist somit auch die maximale Zeit, die für Vorverarbeitung und Auswertung im Echtzeitbetrieb zur Verfügung steht.

Eine analytische Auswertung der Photodiodensignale zielt auf die Erkennung der charakteristischen Signalform ohne Berücksichtigung der weniger aussagekräftigen absoluten Signalhöhe. Unterschiedliche über den Leistungsverlauf getriggerte statistische Methoden, sektionsweise Fits oder die Analyse im Frequenzbereich liefern gute Ergebnisse. Aber auch wenn die absolute Signalhöhe nicht in die Analyse einfließt, ist die Wirkung im Prozess zulässiger Variationen z. B. durch Geschwindigkeit und Düsenabstand so groß, dass insbesondere eine größere Spezifität wünschenswert wäre. Daher wurden verschiedene Methoden der Künstlichen Intelligenz (KI) zur Auswertung der Photodiodensignale getestet. Eine detaillierte Auswertung des Vergleichs ist in Kapitel 13f beschrieben. Als Grundlage für das Training und den Vergleich der KI-Verfahren wurde an einer Laserschneidanlage im Labor ein Datensatz erstellt, der aus ca. 12000 Perioden von Schneidprozessen mit und ohne Schnittabbriss besteht. Bei der Aufnahme von Perioden mit Schnittabbrüchen wurden diese auf unterschiedliche Weise provoziert, so dass verschiedene mögliche Ursachen für einen Schnittabbruch im Datensatz repräsentiert sind. Dazu gehören eine zu hohe Geschwindigkeit, ein falscher Düsenabstand und eine falsche Fokus-



lage. Alle diese aufgenommenen Perioden wurden anschließend manuell in „geschnitten“ und „nicht geschnitten“ entsprechend dem Ergebnis des jeweiligen Schnitts ortsfein klassifiziert, um auf diese Daten Methoden des überwachten Lernens anwenden zu können.

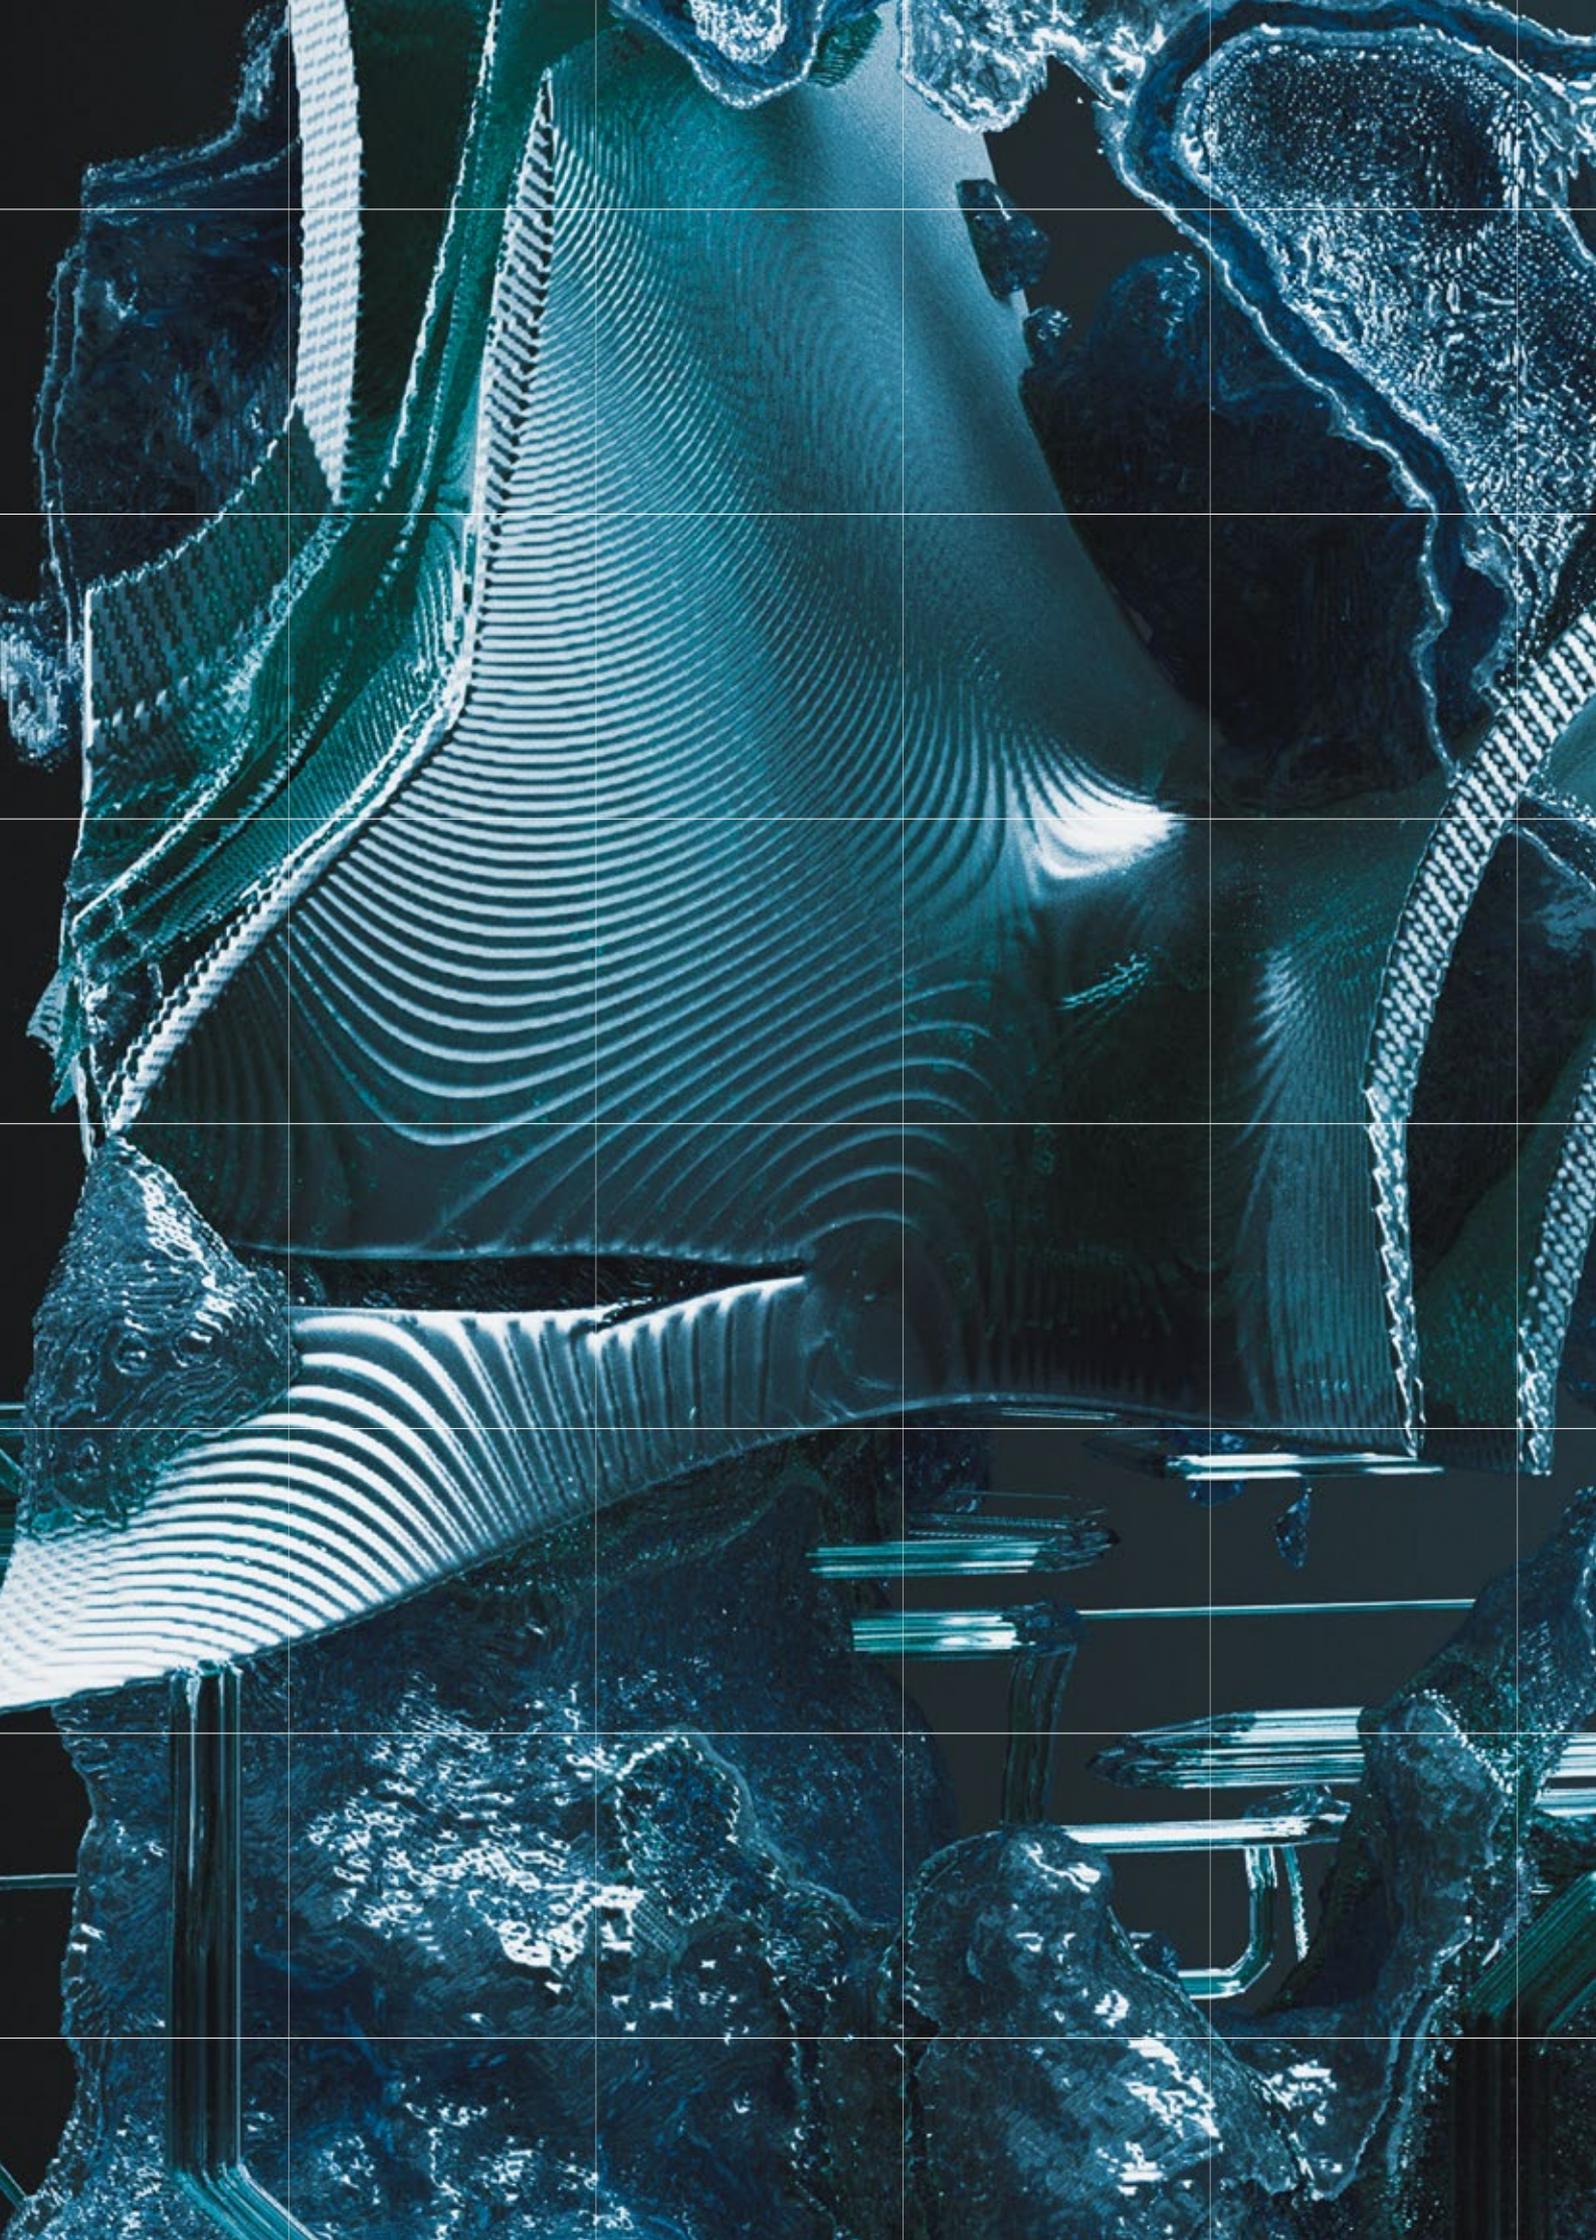
Beim Vergleich verschiedener KI-Verfahren wurde ein Convolutional Neural Network (CNN) identifiziert, das mit 97,9 % die höchste Klassifikationsgenauigkeit aller getesteten Verfahren aufweist (Details siehe Kapitel 13f). Dieses Netzwerk wurde auf dem verwendeten Prozessrechner mit FPGA in das bestehende Programm zur Ansteuerung des Lasers zur Leistungsmodulation und zur Aufnahme des Sensorsignals als Auswerteroutine implementiert. Dabei wurde eine Klassifikationszeit durch das CNN von weniger als 0,8 ms pro Periode und damit deutlich unter der Periodendauer von 2 ms gemessen, sodass die Anforderungen an die Echtzeitfähigkeit erfüllt sind. Für den Einsatz im industriellen Betrieb einer Laser-Blanking-Anlage ist eine Klassifikation mit einer Klassifikationsrate von 97,9 % allerdings nicht ausreichend zuverlässig. Insbesondere falsch positive Ergebnisse, die zu nicht erforderlichem Anlagenstillstand führen, würden die Akzeptanz zum Einsatz der Überwachung reduzieren und Produktivitätsvorteile, die durch die Überwachung generiert werden können, schmälern oder zunichtemachen. Daher ist der KI eine Filterfunktion nachgelagert, die in Form einer Hysterese eine Änderung des Klassifikationszustandes erst durchschaltet, wenn mehrmals hintereinander dasselbe Ergebnis klassifiziert wurde. Der Vorteil ist die deutlich größere Zuverlässigkeit, dem ein trägeres, aber noch akzeptables Ansprechverhalten gegenübersteht. Bewährt hat sich, erst nach drei positiv klassifizierten Perioden eine Reaktion in Form einer kontrollierten Abschaltung auszulösen.

Beim Inferencing, dem aktiven Echtzeiteinsatz des CNN im Schneidbetrieb, ist die Wirkung der Hysterese gut zu erkennen, weil sowohl die unmittelbare Ausga-

be der KI als auch das Ergebnis nach der Hysterese-funktion dargestellt sind (siehe Abbildung 2.2). Bei dem gezeigten Beispielschnitt wurde die Schneidgeschwindigkeit im mittleren Bereich des Schnitts über die Trenngrenze erhöht, während davor und danach die Schneidgeschwindigkeit unter der Trenngrenze liegt. Dadurch wird der mittlere Bereich nicht durchtrennt, während der Anfang und das Ende durchtrennt werden. Dieser Bereich wird durch die KI korrekt erkannt mit einer leichten Verzögerung von ca. 10 ms durch die nachgeschaltete Hysterese-funktion. Einzelne Perioden werden auch außerhalb des nicht getrennten Bereichs als „nicht getrennt“ klassifiziert und gehen in die Auswertung als „false positive“ ein. Diese Klassifikation berücksichtigt jedoch nicht den Umstand, dass der Prozess in diesem Bereich ohne Reserven in einem instabilen Zustand abläuft, auch wenn gerade noch eine Trennung stattfindet. Daraus ergibt sich das Potenzial für weiterführende Arbeiten, die Erkennung dieses Zustands für eine Regelung auszunutzen, um den Prozess durch eine Reduzierung der Geschwindigkeit wieder in einen stabilen Zustand zu überführen, bevor ein fataler Schnittabbruch stattfindet.

Fazit

Für das Laserstrahl-Hochgeschwindigkeitsschneiden, hier am Beispiel des Laser-Blankings, d. h. dem kontinuierlich ablaufenden Zuschnitt von Platinen vom Band, konnte eine Prozessüberwachung realisiert werden, die in einer Echtzeitauswertung auf ms-Skala basierend auf Prozessdaten mit einer zeitlichen Auflösung von 50 ms einen Schnittabbruch erkennt und zur Abwendung weiterer Schäden einen Anlagenstopp auslösen kann. Entscheidend für die sichere Erkennung ist eine Datenqualität, die die relevanten Informationen enthält. Dies wurde hier durch die Anregung des Prozesses und die Auswertung des Antwortsignals auf kleine, determiniert eingebrachte Störungen erreicht.



DATEN



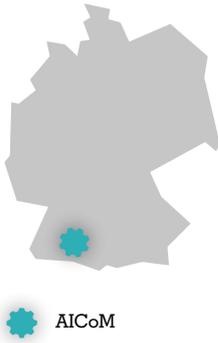
Während das Kapitel „Digitalisierung“ beschreibt, wie die Kommunikation zur Aufnahme, Übermittlung und Speicherung von Daten aufgebaut werden kann, liegt in diesem Kapitel der Fokus auf dem Management von Daten im Produktionskontext. Hier fand der Satz „Shit in, shit out“ weite Verbreitung. Das heißt so viel wie: Je schlechter die Daten den realen Prozess, in dem sie generiert wurden, widerspiegeln, desto schlechter kann der Algorithmus die Zusammenhänge in den Daten erlernen. In diesem Kapitel wird beispielsweise beleuchtet, wie Daten vorverarbeitet und kontextualisiert werden können oder wie mit der Drift von Daten umzugehen ist. Weiterhin wird die Erzeugung von synthetischen Daten aller Art und das Labeling von realen Daten beschrieben. Auch wird die Auswahl von Datenbanken für bestimmte Datentypen erläutert. Dieses Kapitel deckt somit das breite Spektrum des Themenfeldes „Daten“ ab.

*Verantwortlich für dieses Kapitel:
Daniel Hinzmann, Institut für Werkzeugmaschinen und Fabrikbetrieb (IWF) der TU Berlin*

**SHIT IN, SHIT OUT?
HIER ERHALTEN SIE
TIPPS UND TRICKS ZUR
DATENGENERIERUNG,
-AUFBEREITUNG UND
ZU DATENLABELING.**



- 
- 106** Automatisierte Datenvorverarbeitung und Anreicherung von Produktionsdaten
AICoM
- 112** Prozessparalleles Labeling
GeMeKI
- 116** Potenziale der synthetischeren Datenerzeugung in der industriellen Anwendung
ProKI Aachen
- 121** Systematische Datenerfassung und Bewertung der Datenqualität
ProKI Nürnberg
- 126** Labeling multimodaler Prozessdaten beim 3D-Drahtauftragsschweißen
KIKa-IPK
- 131** Drift-Management für Daten von Produktionsprozessen
AutoLern
- 134** Datenmanagement in der Produktionstechnik: Automatisierte Kontextualisierung und Analyse am Beispiel zerspanender Werkzeugmaschinen
ProKI Aachen
- 137** Integration von Sensordatenerfassung, Datenanalyse und KI-Funktionalität in maschinenahem Softwarekonzept zur adaptiven Bearbeitung
ProSLAM



AICoM

AUTOMATISIERTE DATEN- VORVERARBEITUNG UND ANREICHERUNG VON PRODUKTIONS DATEN

Eduardo Souza dos Reis und Carsten Binnig (Technische Universität Darmstadt, System Group)

In der Systems-Gruppe der TU-Darmstadt hat das AICoM-Projekt durch die Automatisierung der Datenvorverarbeitungsschritten dazu beigetragen, die Modellqualität wesentlich zu verbessern, die zum Trainieren eines maschinellen Lernmodells (ML) zur Vorhersage von Maschinenparametern erforderlich sind. Da die AICoM-Daten beispielsweise von mehreren Sensoren in Maschinen erfasst werden, sind fehlerhafte Messwerte vorprogrammiert; der Schritt zur Identifizierung und anschließenden Korrektur dieser fehlerhaften Daten wird als Datenbereinigung bezeichnet. Darüber hinaus berichtet das PTW-Team, dass die Ausführung und Erfassung von Daten für den Maschinenprozess eines einzelnen Werkstücks etwa 1 bis 2 Stunden dauern. Leider erfordert das Training eines ML-Modells Hunderte von Stunden für die Erzeugung von Trainingsdaten. Daher besteht ein eindeutiger Bedarf an der Erzeugung synthetischer Trainingsdaten, ein Schritt, der als Datenerweiterung (Augmentierung) bezeichnet wird. Aus diesem Grund haben wir ein System entwickelt, das sowohl die fehlerhaften Sensordaten bereinigt als auch geeignete synthetische Daten zum Trainieren der ML-Modelle erzeugt.

Automatisierte Vorverarbeitung von Daten

In den letzten Jahren hat es viele Durchbrüche im Bereich der ML gegeben. Die Entwicklung von ML-Pipelines zur Lösung bestimmter Aufgaben ist jedoch nach

wie vor allem andere als trivial und erfordert Fachwissen in vielen Bereichen. So müssen wir bei der Entwicklung einer ML-Pipeline neben dem Training eines Modells nicht nur Kernaufgaben bewältigen (z. B. die Auswahl der Modellarchitektur und die Abstimmung der Hyperparameter), sondern auch viele Aufgaben im Zusammenhang mit der Datenvorverarbeitung und Datenbereinigung, Merkmalsauswahl, Datenerweiterung usw. Diese Aufgaben erfordern in der Regel ein hohes Maß an Fachwissen und stellen somit ein Hindernis für die breite Einführung von ML dar. Außerdem sind diese Schritte selbst mit Expertenwissen sehr zeitaufwendig, da sie viele Entscheidungen und manuelle Experimente erfordern. Unsere Forschung konzentrierte sich daher auf die Automatisierung des gesamten Datenvorverarbeitungsprozesses für die AICoM-Daten und Modelle.

Was heutzutage zur Verfügung steht, sind Automatisierungsmethoden, die für eine der oben genannten Aufgaben hochspezialisiert sind, aber nicht auf die anderen erweitert werden können. Außerdem sind diese Techniken in der Regel nicht optimal in Kombination mit anderen automatisierten Schritten, da sich jede Methode nur um die Optimierung ihrer eigenen verwandten Datenvorverarbeitungsaufgabe kümmert, ohne eine ganzheitliche Sichtweise. Im Rahmen von AICoM wurde eine neue Methode zur End-to-End-Automatisierung der Datenvorver-



beitungs-Pipeline umgesetzt, wie in unserem ersten veröffentlichten Beitrag [1] vorgeschlagen. Die Idee ist, dass DiffML es ermöglicht, das ML-Modell und die gesamte Datenvorverarbeitungs-Pipeline gemeinsam zu trainieren, einschließlich der Datenvorverarbeitungsschritte, wie z. B. Datenbereinigung und Datenerweiterung. Kernidee war es, alle Pipelineschritte differenzierbar zu formulieren, sodass die gesamte Pipeline mit Backpropagation, dem Standardtrainingsverfahren für ML-Modelle, trainiert werden kann. Daher wird die gesamte Data-Engineering-Pipeline auch auf der Grundlage der endgültigen Genauigkeit in der jeweiligen Aufgabe trainiert, nicht in Bezug auf jeden einzelnen Schritt. In demselben Beitrag wurden ein Forschungsfahrplan und zentrale Herausforderungen vorgeschlagen, die systematisch angegangen werden müssen, um vollständig trainierbare ML-Pipelines zu ermöglichen. Wie in unserer Veröffentlichung gezeigt, sorgt dieser Ansatz dafür, die ML-Modellqualität wesentlich zu verbessern.

Automatisierte Datenbereinigung

Als zweiter Beitrag wurde im Rahmen der AICOM ein Verfahren umgesetzt, das sich als ein Schritt in die

Datenvorverarbeitung von DiffML integrieren lässt. Das Verfahren wird als Latent Operators (LOP) bezeichnet und wird in der Veröffentlichung [3] erläutert.

Ein Großteil des manuellen Aufwands von ML-Ingenieur*innen entfällt heute auf die Bereinigung fehlerhafter Eingaben. Innerhalb der Datenvorverarbeitungs-Pipeline wird dies typischerweise in das Erkennen und Reparieren von Fehlern in den Daten untergliedert. Leider sind die Daten oft hochspezialisiert, weisen spärliche und heterogene Fehler auf und die Fehlertypen überlagern sich gegenseitig. Auch hier ist die Datenbereinigung ein mühsamer Prozess, der von Expert*innen durchgeführt wird, und obwohl es Lösungen zur teilweisen Automatisierung gibt, ist die Wahl der besten Methode für jeden Anwendungsfall schwierig und zeitaufwendig.

Die Automatisierung der Datenbereinigung ist daher ein wichtiges Ziel, das die Qualität der ML-Modelle erhöht. Aktuelle Ansätze in dieser Richtung automatisieren die Datenbereinigung mithilfe von ML. Genauer gesagt wird in der Regel ein ML-Modell trainiert, um sowohl die Fehlererkennung als auch die Fehlerbe-

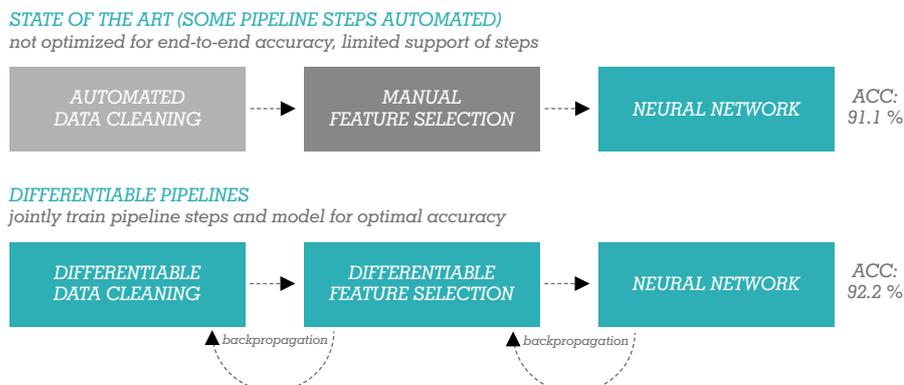


Abbildung 1: Der Unterschied zwischen einer Standard-Data-Engineering-Pipeline und eine DiffML-Lösung. Beachten Sie, dass die gesamte Pipeline trainierbar ist und die endgültige Genauigkeit des neuronalen Netzwerks dazu dient, die Backpropagation zu steuern und jeden Schritt entsprechend anzupassen.



hebung für den jeweiligen Datensatz zu erlernen. ML-basierte Bereinigungsverfahren zeigen zwar vielversprechende Ergebnisse, können aber nur Fehler bereinigen, die sie beim Training gesehen haben. Daher bleiben viele Fehler unentdeckt und haben einen negativen Einfluss auf die Genauigkeit des ML-Modells. Im Rahmen von AICoM können nicht alle Fehlertypen, die in der Praxis auftreten können, zuverlässig vorhergesagt werden, daher muss eine robustere Lösung entwickelt werden.

Bestehende ML-basierte Ansätze zur Datenbereinigung basieren meist auf dem Paradigma des überwachten Lernens, bei dem ein Trainingsdatensatz mit fehlerbehafteten und bereinigten Daten erforderlich ist. Die Standard-Pipeline für das Erlernen einer ML-basierten Bereinigungsverfahren sieht folgendermaßen aus: In den Trainingsdaten wird jede Zelle eines Tabellen-Tupels als „schmutzig“ oder „sauber“ gekennzeichnet, was uns ermöglicht, ein Fehlererkennungsmodell zu trainieren, d. h. ein Modell, das entscheidet, ob eine Tabellenzelle fehlerhaft ist oder nicht. Anschließend muss für jede Zelle, die einen Fehler enthält, der Fehlertyp (z. B. fehlende Werte, Rauschen) identifiziert und eine entsprechende Fehlerreparaturfunktion angewendet werden.

Wie bereits erwähnt, ist es in vielen Bereichen, wie dem AICoM-Projekt, angesichts der Heterogenität der Fehlertypen in den Daten schwierig, einen Trainingsdatensatz zu haben, der alle möglichen Fehler abdeckt, die bei allen Sensormessungen auftreten können. Erschwerend kommt hinzu, dass die meisten Fehlererkennungsverfahren typischerweise an eine Reihe von vordefinierten Fehlertypen gebunden sind, sodass jede Fehlerreparaturmethode, die von einem Detektor abhängt, ebenfalls auf diese Untermenge beschränkt ist. Idealerweise müssen Datenbereinigungsverfahren Fehler beheben, die beim Training nicht erkannt wurden. In solchen Fällen müssen sich die ML-Modelle auf induktive Verzerrungen verlassen, die während

des Trainings gelernt wurden und die spezifisch für den Fehlersatz sind, der in den verschmutzten Daten vorhanden ist. Diese Daten lassen sich möglicherweise weder auf neue, nicht gesehene Fehlertypen noch auf dieselben Fehler in einer anderen Teilmenge von Tupeln verallgemeinern.

Dieses Paradigma wurde durchbrochen, indem jeder Fehlertyp mit der gleichen Fehlerbehebungsmethode gelöst wurde. Die Einschränkung, verschiedene Funktionen oder Modelle für verschiedene Fehlertypen zu haben, ergibt sich aus dem Versuch der Datenbereinigung im Eingaberaum. Stattdessen schlagen wir LOP als Datenbereinigungslösung mit Generalisierung für Fehlertypen vor, die während des Trainings nicht gesehen wurden, was die Notwendigkeit einer externen Fehlererkennungsverfahren erübrigt. Die Hauptidee besteht darin, die Aufgabe der Datenbereinigung in den latenten Raum innerhalb des ML-Modells zu verlagern.

Um zu vermeiden, dass unterschiedliche Funktionen zur Lösung verschiedener Fehlertypen benötigt werden, werden die Daten auf einen geformten latenten Raum mit strukturell getrennten sauberen und schmutzigen Regionen projiziert. Darauf aufbauend wird unser LOP-Modell trainiert, um schmutzige Daten auf eine bestimmte Dimension des geformten latenten Raums abzubilden, die orthogonal zu der für saubere Daten verwendeten Region ist. In unserem Modell wird das Eingabedatum, wenn es sauber ist, in die saubere Region projiziert, und wenn es schmutzig ist, wird es irgendwo entlang der von unserem Modell gelernten Fehlerdimension projiziert. Darüber hinaus vereinfacht sich eine Fehlerreparatur auf den Prozess, diese Projektion entlang der Fehlerdimension zurück zu dem Punkt zu verschieben, an dem sie sich mit der sauberen Region schneidet. Ein entscheidendes Vorteil besteht darin, dass Fehler, die beim Training nicht erkannt wurden, repariert werden können, indem sie ebenfalls entlang dieser Fehlerdimension zurückprojiziert werden.

Um LOP in der Datenbereinigung zu evaluieren, wurde unser Modell auf einem einfachen Satz von Fehlern trainiert und unsere Ergebnisse mit anderen Ansätzen auf schmutzigen Daten verglichen, die durch einen ungesehenen Satz von Fehlerfunktionen erzeugt wurden. Diese wurden durch den veröffentlichten Datenbereinigungs-Benchmark REIN [2] bereitgestellt. Unsere ausführliche Evaluierung zeigt, dass dieser Ansatz nicht nur robuster ist, sondern auch auf unbekannte Fehlertypen verallgemeinert werden kann. Zum Beispiel reduzierte die Anwendung von LOP auf mehrere verschmutzte Datensätze von REIN die Fehlermetrik auf einem der komplexen Datensätze um 20 % im Vergleich zur besten Alternative, obwohl während des Trainings nicht einmal alle Fehlertypen gesehen wurden.

Automatisierte Anreicherung von Daten

Bei den AICoM-Daten ist die Datenbereinigung nur ein Teil des Problems. Eine andere Herausforderung

ist die Datenerweiterung. Daher wurde die LOP-Strategie erweitert, um neue Datenpunkte aus diesem geformten latenten Raum synthetisch zu erzeugen. Dazu werden zunächst die vom PTW-Team bereitgestellten Trainingstupel, die bei einer realen Werkstückbearbeitung erfasst wurden, in unseren geformten latenten Raum projiziert. Anschließend werden diese projizierten Trainingstupel als Anker verwendet und werden um die während des Trainings abgebildete Fehlerrichtung bewegt. Folglich ergibt sich bei jeder Verschiebung ein neuer Datensatz, der für das Training verwendet wird. Auf naive Weise würden diese synthetisch erzeugten Daten nur Rauschen enthalten, aber aufgrund unseres neuen LOP-Verfahrens wird die Korrelation zwischen den Merkmalen auch in den synthetischen beibehalten. Die resultierenden Daten respektieren die Maschineneigenschaften, die aus den realen Daten gelernt wurden. Abbildung 2 zeigt die Erzeugung synthetischer Daten für ein neues Werkzeug für ein gefertigtes Werkstück.

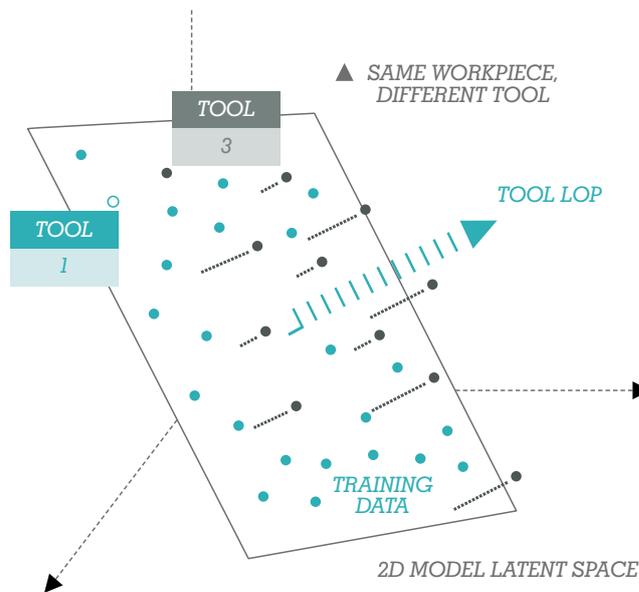


Abbildung 2: Beispiel für die Erzeugung synthetischer Daten mittels Augmentierung. Alle Trainingspunkte (blau) werden um den gleichen Betrag verschoben, um die neue Zeitreihe für das synthetische Tupel (rot) zu erhalten. Dieses neue Tupel simuliert den Einsatz von Werkzeug 3 anstelle von Werkzeug 1, um das gleiche Werkstück zu fertigen.



Evaluierung der Methoden auf realen Produktionsdaten

Nach einer erfolgreichen Evaluierung mit Benchmark-Daten wurde die LOP-Methode auf reale AICom-Daten angewendet. Im Zusammenhang mit der Bearbeitung von Werkstücken lieferten PTW Zeitreihen für jeden der Sensoren in der Maschine. Ihre Aufgabe ist es, das Verhalten (Drehmoment) jedes Motors sowie der Spindel / des Werkzeugs während des gesamten Prozesses vorherzusagen, jedoch für Werkstücke, die während des ML-Modelltrainings nicht gesehen wurden. Mit anderen Worten, das Ziel ist die Generalisierung auf ungesehene Daten, ohne die zeitliche Kohärenz oder die physikalischen Eigenschaften der Maschine zu verletzen. Daher muss die LOP-Methode es ermöglichen, Schnitte einer Zeitreihe zu nehmen, die im physikalischen Sinne machbar sind und auch kohärent bleiben, wenn sie zu einem vollständigen Prozess verkettet werden. Angenommen, der Prozess begann mit der Bearbeitung von Werkzeug 1. Es ist nicht möglich, für einen Bruchteil des Zeitintervalls (Millisekunden) zu Werkzeug 2 zu wechseln und dann zu Werkzeug 1 zurückzukehren. Dieses Szenario ist physikalisch nicht möglich und würde daher in der Praxis nie vorkommen.

Um unseren LOP-Ansatz auf diese Zeitreihendaten anwenden zu können, wurde eine wesentliche Änderung vorgenommen: Ein Ausschnitt der Zeitreihe (mehrere Datenpunkte) wurde auf einmal in unseren latenten Raum projiziert. Danach wurden alle zusammen um die gleiche Strecke verschoben, anstatt jeden Datenpunkt unabhängig voneinander zu verschieben, wie in den vorherigen Experimenten. Diese Änderung ist auf die Natur der AICom-Daten (Zeitreihen) zurückzuführen, bei denen die zeitliche Konsistenz ein Schlüsselmerkmal ist. Bei der Generierung synthetischer Daten zum Trainieren von ML-Modellen müssen nicht alle nicht durchführbaren Fälle vermieden werden, aber wenn die Bedingungen klar sind, sollte diese Art von

Verzerrung von der Methode berücksichtigt werden. Um die Auswirkungen der von uns vorgeschlagenen Strategie zur Datenerweiterung zu bewerten, wurden 10 Experimente mit Daten von 10 verschiedenen Werkstücken durchgeführt. Anschließend wurde ein ML-Modell zur Vorhersage des Drehmoments der einzelnen Motoren während der Fertigung des Werkstücks trainiert. Nur die ersten 5 Experimente für das Training wurden verwendet. Danach wird das trainierte Modell an den verbleibenden 5 Experimenten ausgewertet, um eine Überanpassung (Auswendiglernen der Trainingsdaten) zu vermeiden. Durch die Anwendung unserer LOP-Methode auf die bereitgestellten PTW-Sensordaten konnte die Vorhersagegenauigkeit für die in den Abbildungen 3 und 4 dargestellten Tests um 25 % verbessert werden. Die Fehlanpassung der Vorhersagen mit einem ML-Modell, das nur auf den Trainingsdaten trainiert wurde, ist signifikant, während der größte Teil davon durch die Einbeziehung synthetischer Tupel behoben wird. Dieses Verhalten ist auf die mangelnde Vielfalt von nur 10 Experimenten zurückzuführen, wodurch das trainierte Modell nicht auf neue Szenarien übertragen kann.

Zusammenfassung

In diesem Beitrag werden unsere Arbeiten aus dem Bereich Automatisierte Datenvorverarbeitung und Anreicherung von Produktionsdaten vorgestellt. Die Arbeiten beschreiben neue Ansätze, die basierend auf Methoden des maschinellen Lernens die Daten bereinigen und eine Dateierweiterung durchführen, damit die Qualität von Vorhersagemodellen in der Produktion verbessert werden kann. In einer Evaluierung mit realen Produktionsdaten wurde gezeigt, dass dadurch die Vorhersagequalität der Modelle um 25 % gesteigert werden kann.

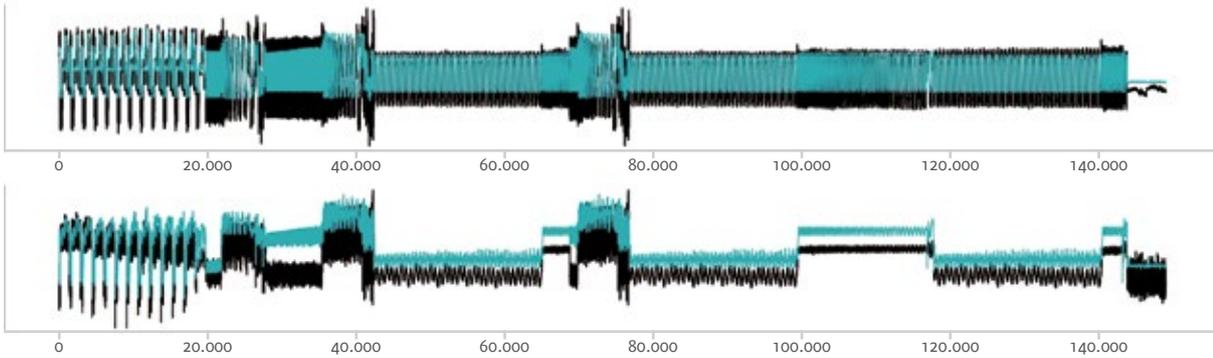


Abbildung 3: Ergebnisse ohne Datenerweiterung mit LOP. Wahres Drehmoment der Motoren Y (oben) und Z (unten) über ein komplettes Werkstück in schwarzer Farbe, überlagert durch das vorhergesagte Drehmoment mit unserem ML-Modell. Beachten Sie, dass deutliche Fehler bei der Vorhersage (schwarze Linie) zu sehen sind.

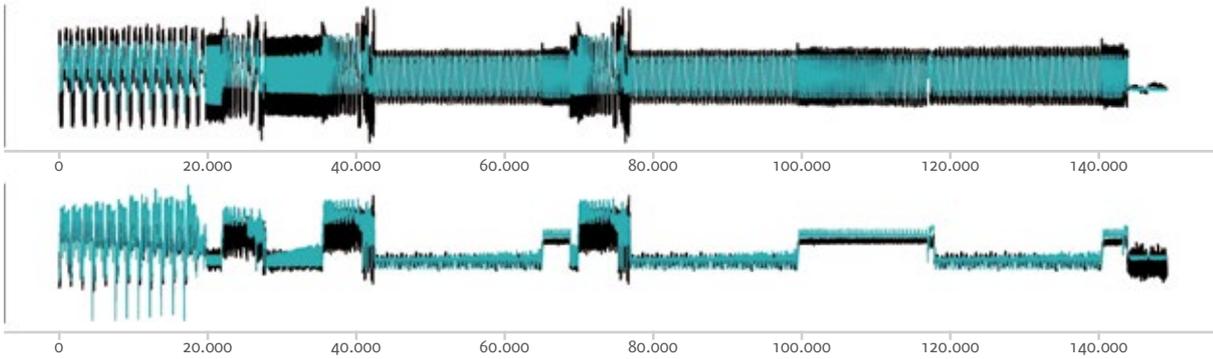
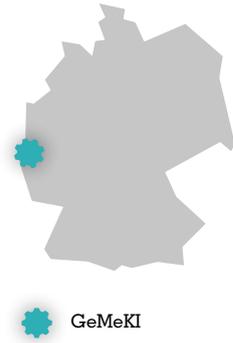


Abbildung 4: Ergebnisse auf erweiterten Daten mit LOP. Wahres Drehmoment der Motoren Y (oben) und Z (unten) über ein komplettes Werkstück (schwarz), überlagert durch das vorhergesagte Drehmoment mit unserem ML-Modell. Die Verbesserung ist in der Übereinstimmung zwischen den beiden Zeitreihen zu sehen.

Literatur

- [1] Hilprecht, B., Hammacher, C., Reis, E.S., Abdelaal, M. and Binnig, C., 2023, June. Diffml: End-to-end differentiable ML pipelines. In Proceedings of the Seventh Workshop on Data Management for End-to-End Machine Learning (pp. 1-7) @ ACM SIGMOD..
- [2] Abdelaal, M., Hammacher, C. and Schoening, H., 2023. Rein: A comprehensive benchmark framework for data cleaning methods in ML pipelines. EDBT.
- [3] Reis, E.S, Abdelaal, M. and Binnig, C., 2025, Generalizable Data Cleaning of Tabular Data in Latent Space. Submitted to VLDB'25.



PROZESSPARALLELES LABELING

GeMeKI

Hossein Omid Beiki, Manuel Belke (Werkzeugmaschinenlabor WZL der RWTH Aachen)

Hybride Intelligenz in der Produktion: Durch prozessparalleles Labeling kann die Fachexpertise des Menschen nahtlos in die KI einfließen.

Künstliche Intelligenz (KI) ist ein Gamechanger in der modernen Produktion. Sie kann zur prozessnahen Qualitätsüberwachung an der Produktionslinie eingesetzt werden und zur Erhöhung der Produktqualität sowie zur Reduktion des Ausschusses beitragen. KI-basierte Assistenzsysteme analysieren kontinuierlich die Produktionszustände und beurteilen sie. Sie unterstützen den Menschen bei der Optimierung der Produktionsprozesse, indem sie frühzeitig auf potenzielle Fehler hinweisen und Maßnahmen zur Behebung vorschlagen. Solche KI-Systeme kombinieren menschliche Fachexpertise mit datenbasierten Analysen, wodurch robustere und effizientere Produktionssysteme entstehen.

Daten sind das Herzstück jeder KI. Sie ermöglichen es der KI, aus vergangenen Erfahrungen zu lernen, Trends und Muster zu erkennen und darauf basierend Vorhersagen für zukünftige Fälle zu treffen. Damit diese Vorhersagen präzise und verlässlich sind, ist kontinuierliches Feedback in Form von Labels erforderlich. Diese Labels können Informationen über den Zustand des Produkts, die Qualität, Produktionsparameter oder potenzielle Defekte enthalten. Die Daten, die mit La-

beln versehen sind und zum Training der KI eingesetzt werden, werden als Trainingsdaten bezeichnet.

Meist übernimmt der Mensch als Wissensträger und Fachexperte das Labeling von Trainingsdaten sowie die Ergebnisüberwachung in der Anwendungsphase. Dies setzt eine enge Verzahnung zwischen dem Menschen und der KI voraus, die durch ein prozessparalleles Labeling und Feedbackschleifen verstärkt werden kann. Durch das prozessparallele Labeling, bei dem das Labeln direkt während der Fertigung erfolgt, wird das Fachwissen der Mitarbeitenden nahtlos mit der maschinellen Präzision der KI verknüpft. Dies führt zu einer Verbesserung der Effizienz und Qualität. Im folgenden Artikel wird detailliert erläutert, wie prozessparalleles Labeling zu einer effizienten KI-Applikation beitragen kann und welche technischen und organisatorischen Herausforderungen dabei zu bewältigen sind.

Chancen und Risiken des prozessparallelen Labelings

In der Produktion ist es entscheidend, dass KI-Systeme verlässliche Vorhersagen treffen. Um dies sicherzustellen und ein schnelles Training zu ermöglichen, werden sowohl Maschinenparameter und Prozessinformationen als auch die menschliche Expertise genutzt. Zur Beurteilung der Bauteilqualität müssen



Menschen die Daten labeln und so das Training der KI ermöglichen. Das Labeln der Daten führt dazu, dass ein Teil der Fachexpertise des Menschen an die KI weitergegeben wird.

Prozessparalleles Labeling ermöglicht es Fachkräften, ihre Bewertungen direkt während des Produktionsprozesses einzubringen. Diese Einbindung des Menschen in den Labeling-Prozess hat unter anderem den Vorteil, dass die Werkenden stärker in den Entstehungsprozess der KI integriert werden, was die Akzeptanz der Technologie erhöht. Ein weiterer technischer Vorteil besteht darin, die kontinuierliche Interaktion zwischen Mensch und KI sicherzustellen, damit der Mensch die Vorschläge der KI nutzen und korrigieren kann und weiterhin die letzte Entscheidungsinstanz bleibt. Dies erfordert

technische Schnittstellen und Feedback-Mechanismen zwischen dem Menschen und der KI.

Eine Herausforderung besteht darin, dass die Werkenden durch das Labeln nicht von ihrer eigentlichen Arbeit abgelenkt werden dürfen. Je nach Anwendungsfall variieren die Methoden zur Datenaufnahme und -vorverarbeitung sowie das Labeling selbst. Bei niederfrequenten Fügeprozessen erlaubt die Aufnahme von Daten das prozessparallele Labeling durch den Menschen, ohne die Produktivität wesentlich zu beeinträchtigen. Dagegen erfordern hochfrequente Fräsprozesse eine Vorverarbeitung der Daten zur effizienten Speicherung. Bei Fräsprozessen ist es zudem erforderlich, auffällige Zeitpunkte ohne Unterbrechung des Prozesses zu kennzeichnen und nach-

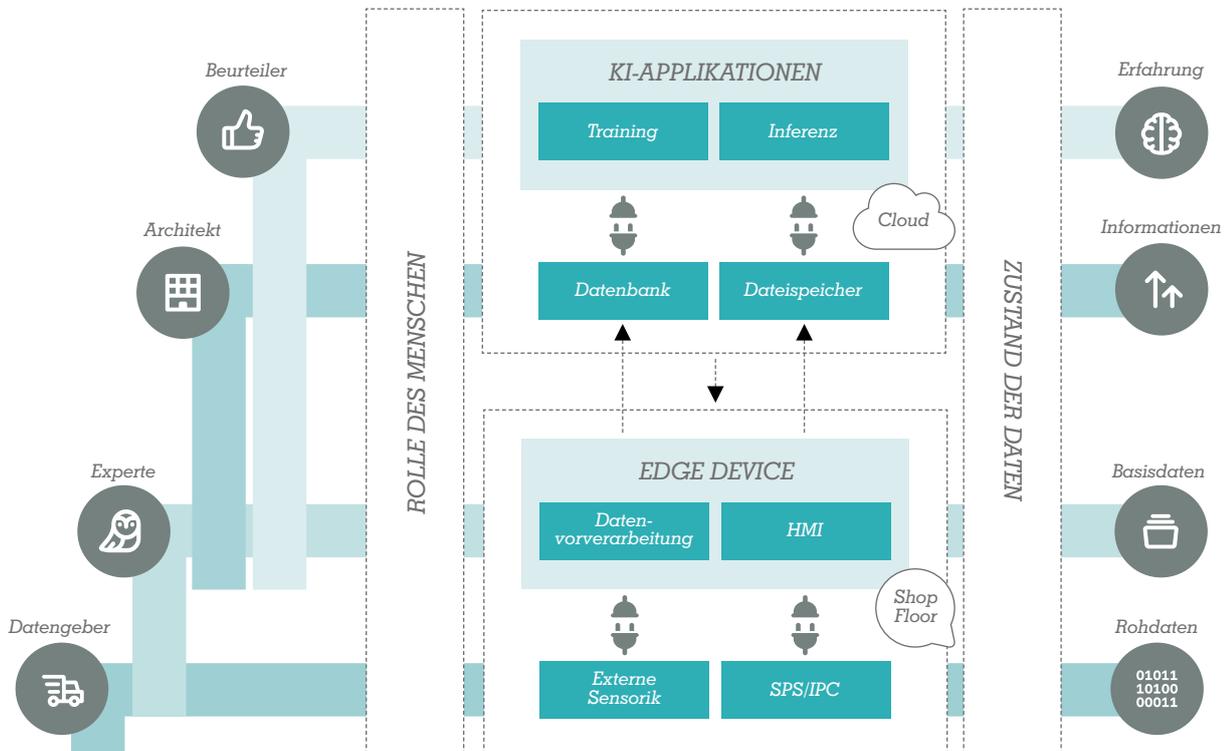


Abbildung 1 Architektur einer Mensch-Maschine-Interaktion zum prozessparallelen Labeling



trüglich weitere Informationen hinzuzufügen, um die gewonnenen Daten effektiv zu nutzen und die Produktionsqualität kontinuierlich zu verbessern.

Umsetzung prozessparalleler Labelings: Erkenntnisse aus der Entwicklung

In GeMeKI wurden für drei Anwendungsfälle: (1) Fügen, (2) Trennen und (3) Umformen, Möglichkeiten des prozessparallelen Labelings konzipiert und umgesetzt. Dabei spielt die Datenaggregation eine zentrale Rolle, um qualitativ hochwertige und verwertbare Daten für die Entwicklung von KI-Applikationen bereitzustellen. Neben der vorhandenen Maschinensensorik, die an eine SPS oder einen IPC zur Steuerung der Maschine angeschlossen ist, wird je nach Anwendungsfall zusätzliche externe Sensorik zur Entwicklung der KI-Applikation benötigt (siehe Abbildung 1). Die Daten dieser Sensoren werden an ein oder mehrere Edge Devices geschickt. Ein Edge Device übernimmt die Datenvorverarbeitung, wandelt Rohdaten in Basisdaten um und stellt ein Human-Machine-Interface (HMI) zur Verfügung.

HMIs ermöglichen es Prozessexperten, Prozessdaten zu überwachen und Entscheidungen basierend auf Erfahrungswerten zu treffen. Zusätzlich bieten sie eine Möglichkeit zum prozessparallelen Labeling von Daten, wodurch Werkende mit minimalem Aufwand Label vergeben können, ohne ihre Arbeit zu unterbrechen. Diese Label, zusammen mit den Prozessdaten, werden durch das Edge Device in Datenbanken oder einem Datenspeicher abgelegt. So werden die Daten aggregiert und sind durch Metadaten, wie die ID des Bauteils, unterscheidbar.

In Abbildung 1 wird die Architektur der oben beschriebenen Interaktion detailliert dargestellt. Diese umfasst verschiedene menschliche Rollen wie Beurteiler, Architekt, Experte und Datengeber sowie unterschiedliche Datenzustände wie Rohdaten, Basisdaten, Informationen und Erfahrungen. Um die Taktzeit einzu-

halten, muss der Datenfluss innerhalb der gesamten Architektur ohne Unterbrechungen erfolgen. Dies erfordert die Auswahl der passenden IT-Infrastruktur und Datentransferprotokolle.

Es hat sich im Projekt GeMeKI herausgestellt, dass ein benutzerfreundliches HMI von großer Bedeutung ist. Dies ermöglicht es dem Werkenden, mit minimalem Aufwand Labels zu vergeben, während sie sich weiterhin auf den Prozess konzentrieren. Nach Interviews mit Produktionsleitenden und Werkenden wurde festgestellt, dass physische Knöpfe eine praktische Option darstellen, da die Werkenden bereits mit der Nutzung physischer Bedienelemente vertraut sind. Alternativ können digitale Knöpfe in einem grafischen User Interface (GUI) auf einem Touchscreen verwendet werden.

In der Produktionslinie bei der Miele & Cie. KG wurde ein Klebeprozess (Anwendungsfall Fügen) untersucht. Aufgrund der späten Verortung in der Fertigungskette sind Qualitätsprobleme und Produktivitätsengpässe beim Kleben besonders teuer. Bei GeMeKI wurde deshalb der Dispensierungsprozess des Klebstoffs erfasst und der Einsatz von KI zur vorzeitigen Fehlererkennung untersucht. Der Klebstoffauftrag erfolgt derzeit teilautomatisiert. Ein effizientes Beschreibungsmodell für diesen Prozess existiert nicht, insbesondere aufgrund einwirkender Parameter wie Temperatur, Dispensionsdruck und Düsenverschleiß. Daher muss der Prozess visuell vom Bediener geprüft werden. Da der Klebstoff transparent und das zu verklebende Bauteil klein ist, ist die visuelle Prüfung durch Bediener mit Aufwand und Unsicherheiten verbunden. Abbildung 2 zeigt die HMI des Klebeprozesses zur Fehlerdokumentation. Oben wird dem Werkenden prozessparallel das Bild der aktuellen Kleberaupe eingeblendet. Die Geometrie und weitere Eigenschaften der Kleberaupe dienen als zuverlässige Qualitätsindikatoren für das Ergebnis des Klebeprozesses. Der Werkende hat die Möglichkeit, auf Basis des angezeigten Bildes die Kleberaupe zu labeln; hierfür wurden sowohl Bildschirme als auch physische Druckknöpfe



integriert. Zusätzlich kann der Werkenden Details der Fehler sowie Informationen zur Fehlerbehebung dokumentieren. Im Hintergrund werden die durch den Bediener erfolgten Dokumentationen zusammen mit weiteren Prozessdaten, wie Zeitstempel sowie Einstellungen der Dispenserstation, und Metadaten, wie die ID des Bauteils, in der Datenbank gespeichert.

Nach dem Training der KI ist es möglich, den Prozess auf Basis historisch durchgeführter Verbesserungen zu optimieren, indem die KI Vorschläge für Einstellparameter der Maschinen vorschlägt. Hierbei wird die Interaktion zwischen Mensch und Maschine intensiviert. Die Werkenden erhalten beispielsweise ähnliche Bilder aus der Vergangenheit angezeigt, um die Entscheidungsfindung zu unterstützen und das Labeln neuer Daten zu vereinfachen. Ansätze des Active Learnings können genutzt werden, um die Werkenden ausschließlich neue Bilder labeln zu lassen, die eine geringere Übereinstimmung mit bereits aufgenommenen Daten aufweisen. Dies verbessert die Effizienz des

Labeling-Prozesses und die Qualität der KI-Modelle. Insgesamt hat sich bei GeMeKI herausgestellt, dass es zur Realisierung einer hybriden Intelligenz essenziell ist, dass die Werkenden ständig Rückmeldung geben und die KI bewerten. Die Interaktion umfasst die Anzeige von Prozessdaten, das Labeln von Daten und die kontinuierliche Rückmeldung und die Bewertung der KI. Diese Prozesse ermöglichen eine ständige Verbesserung und Anpassung der Produktionsprozesse, wodurch die Produktionsqualität kontinuierlich gesteigert wird. Das prozessparallele Labeling verknüpft das Fachwissen der Mitarbeitenden nahtlos mit der maschinellen Präzision der KI, was zu einer deutlichen Verbesserung der Effizienz und Qualität führt. Die Einbindung der Werkenden in den Entwicklungs- und Produktionsprozess ist somit von zentraler Bedeutung, um die Potenziale hybrider Intelligenz voll auszuschöpfen. Die Entwicklung benutzerfreundlicher Mensch-KI-Schnittstellen ist dabei zentral, um eine effiziente und akzeptierte Nutzung der KI-Modelle zu gewährleisten.

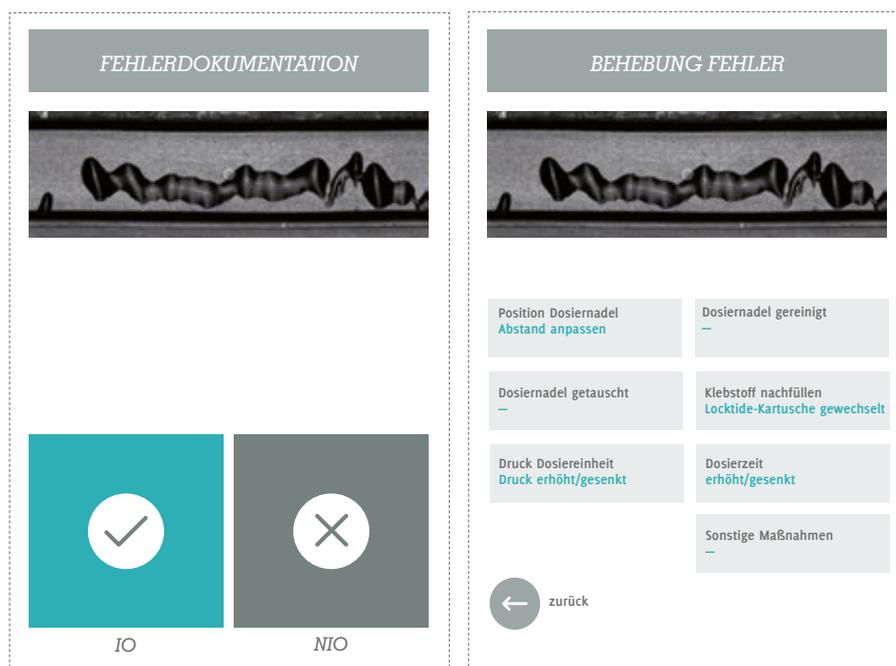
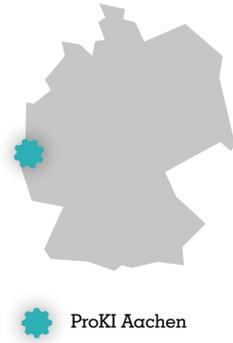


Abbildung 2 HMI des Anwendungsfalls Fügen, Einsatz an der Produktionslinie bei Miele & Cie. KG



ProKI Aachen

POTENZIALE DER SYNTHETISCHEN DATENERZEUGUNG IN DER INDUSTRIELLEN ANWENDUNG

Josefine Monnet, Petar Tesic (Werkzeugmaschinenlabor WZL der RWTH Aachen)

Synthetische Daten liefern die Lösung für den häufigsten Showstopper von KI-Applikationen: das Datenproblem.

Es herrscht Einigkeit über die Potenziale des Einsatzes von KI-Algorithmen: So prognostiziert McKinsey ein zusätzliches Wirtschaftswachstum von 10 Milliarden Euro, während die Unternehmensberatung Bain & Company von potenziellen Produktivitätssteigerungen zwischen von 30 % bis 50 % spricht^[1,2]. Ein häufiger Showstopper bei der Einführung von KI-Applikationen ist und bleibt jedoch das Datenproblem^[3]. Denn: Performante KI-Modelle benötigen sehr große und diverse Datensätze. Dies stellt im Hinblick auf kleiner werdende Losgrößen und eine steigende Produktvarianz eine entscheidende Hürde dar. Zwar gibt es „Tricks“, wie man Datensätze erweitern kann, jedoch stößt auch diese Datenaugmentation, beispielsweise das Rotieren oder Spiegeln sowie Hinzufügen von stochastisch verteiltem Rauschen, an Grenzen, da der KI-Algorithmus nur begrenzt neues erlernt^[4]. Im Datensatz müssen jedoch alle zu detektierenden Merkmale und Klassen zu Genüge vorliegen. Ein typischer produktionstechnischer Use-Case ist die Klassifizierung von Gut- und Schlechtteilen^[5]. Häufig sind nicht genug Bilder von Schlechtbauteilen in unterschiedlicher Ausprägung vorhanden. Diese Varianz muss der Datensatz widerspiegeln. Neben der Herausforderung, ausreichend Bilder zu generieren, ist auch der Aufwand für die Annotation (Labeln) der

Bilddaten nicht zu unterschätzen. Dieser Aufwand wird mit ca. 80 % der Gesamtkosten von KI-Projekten beziffert. Gleichzeitig birgt das manuelle Labeling eine potenzielle Fehlerquelle^[6]. Die State-of-the-Art-KI-Modelle zur Bilddatenverarbeitung arbeiten mit Datenformaten, die entweder eine sogenannte Bounding Box, also einen rechteckigen „Kasten“, der parallel zu den Bildrändern liegt, oder eine pixelweise Annotation der zu detektierenden Objekte beinhalten. In beiden Fällen besteht das Potenzial eines fehlerhaften Labelings, welches das Training des KI-Modells erschwert und seine Performanz verschlechtert.

Dieses Datenproblem kann durch den Einsatz von synthetischen Daten gelöst werden. Im Vergleich zu Trainingsdaten, die in der realen Welt gesammelt werden, werden synthetische Daten automatisiert durch Simulation erzeugt. Im Fall von Bilddaten gibt es dabei grundsätzlich die Möglichkeit, eine automatisierte Pipeline mit fotorealisticem Rendering oder Generativer KI zu nutzen^[7]. Letztere nutzt dabei ein KI-Modell, um Daten zu erzeugen, bevor ein zweites KI-Modell mittels dieser Daten trainiert wird. Für das Training der generativen KI wird jedoch immer noch ein gewisser Datensatz benötigt, damit das Modell in der Lage ist, die entscheidenden Merkmale zu erkennen und geeignete Bilder zu erzeugen, die den Datensatz vergrößern. Durch eine automatisierte Pipeline kann der Bedarf eines ausreichend großen und varianzreichen Datensatzes gedeckt werden. Verfügt man



über detaillierte Informationen zur Bauteilgeometrie sowie - im Falle einer Gut-/Schlecht-Klassifizierung - über die Charakteristika und Ausprägungen möglicher Defekte, lassen sich diese Daten in einer Simulationssoftware präzise modellieren und innerhalb der bekannten Varianz automatisch randomisieren. Dies ermöglicht die Generierung einer Vielzahl synthetischer Datensätze, die die reale Produktvielfalt und potenzielle Qualitätsabweichungen repräsentativ abbilden. Dieser Ansatz bietet nicht nur eine effiziente Methode zur Datengenerierung, sondern auch die Möglichkeit, seltene oder kritische Szenarien gezielt zu simulieren, was die Robustheit des trainierten Modells erheblich steigert.

Diese Daten können bereits frühzeitig in der Produktentwicklung generiert werden, noch bevor ein physisches Produkt existiert. Ein bedeutender Pluspunkt liegt in der Möglichkeit, Defekte auf Bauteilen zu simulieren, ohne reale Ausschussmengen produzieren zu müssen. Darüber hinaus kann auch die Annotation der Daten automatisiert erfolgen. Der

manuelle Labeling-Aufwand sowie daraus resultierende Ungenauigkeiten entfallen somit vollständig. Eine zentrale Herausforderung bleibt der „Sim2RealTransfer“, bei dem die unvermeidbaren Unterschiede zwischen Simulation und Realität die Übertragbarkeit von KI-Modellen einschränken^[8]. Die Möglichkeiten des fotorealistischen Renderings, gepaart mit einer Randomisierung von Beleuchtungs-, Hintergrund- und Kameraparametern, sorgen für eine Konvergenz von Simulation und Realität und schließen somit den „Sim2Real-Gap“. Eine weitere Verbesserung kann zudem durch die Anreicherung des Trainingsdatensatz mit einzelnen wenigen realen Trainingsdaten erreicht werden.^[8, 9]

Die für die Erstellung synthetischer Daten benötigten Informationen stammen aus verschiedenen Phasen des Produktlebenszyklus, wie in Abbildung 1 gezeigt^[9]. CAD-Dateien, die direkt aus dem Engineering von Produkt und Produktion stammen, bilden die Grundlage für den Rendering-Prozess. Die Materialwahl erfolgt im Rahmen des Produktdesigns, kann jedoch

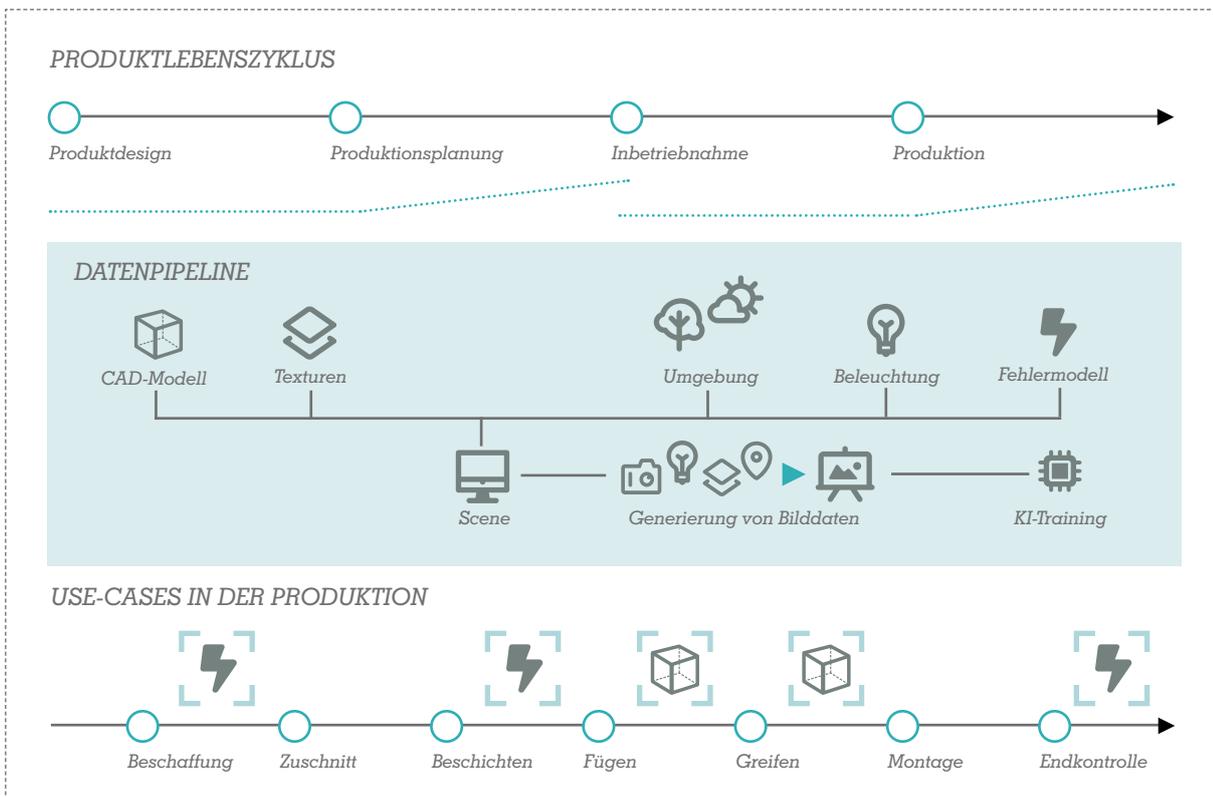


Abbildung 1: Datenpipeline für die Erzeugung synthetischer Daten über den Produktlebenszyklus [9]

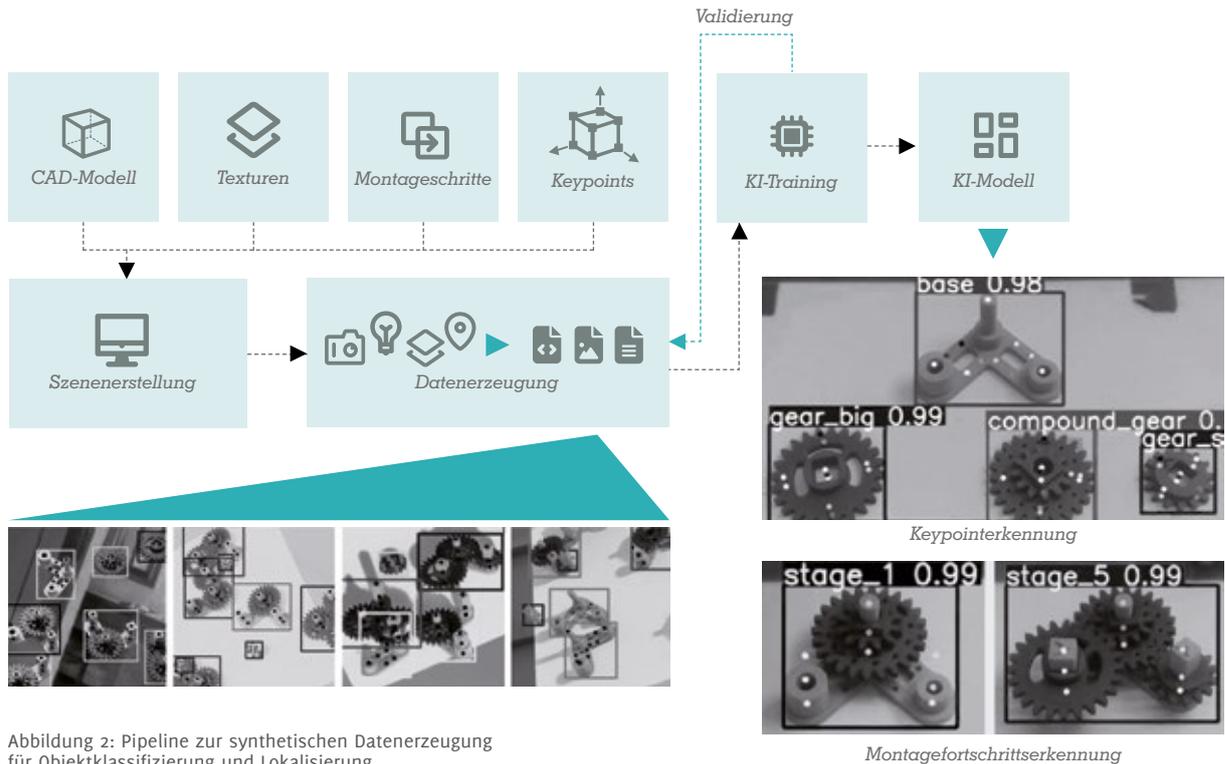


Abbildung 2: Pipeline zur synthetischen Datenerzeugung für Objektklassifizierung und Lokalisierung

je nach Lieferanten oder vorangegangenen Prozessen, wie Schleifen oder Polieren, variieren. Auch die Nachbildung der Umgebung spielt eine wichtige Rolle. Objekte in der Umgebung, die im Sichtfeld der Kamera auftauchen oder Schatten werfen, müssen in der simulierten Umgebung nachgebildet werden. Besonders wichtig ist die möglichst realistische Nachstellung der Lichtverhältnisse. In der Simulationsumgebung stehen verschiedene Lichtquellen zur Verfügung, die ausgewählt und ausgerichtet werden müssen. In der Produktion bieten sich zahlreiche Einsatzmöglichkeiten wie beispielsweise Werkzeuge zur Qualitätssicherung oder Objekterkennungs- und Lokalisierungssysteme.

Objekterkennung und Lokalisierung

Die Fähigkeit zur Klassifizierung von Objekten und die Bestimmung ihrer Position im Raum sind grundlegende Voraussetzungen für die Umsetzung flexibler und effizienter Automatisierungslösungen. Insbesondere für Smart-Robotics-Applikationen bilden diese Fähigkeiten das Fundament für fortschrittliche Interaktionen zwischen Maschinen und ihrer Umgebung^[10]. In den letzten Jahren hat die intensive Forschung auf dem Gebiet der Deep-Learning-basierten Computer Vision zu bemerkenswerten Fortschritten geführt. Diese Entwicklung, gepaart mit der stetig wachsenden

Rechenleistung moderner Grafikprozessoren, hat eine breite Palette von leistungsfähigen Klassifizierungs- und Lokisierungsalgorithmen hervorgebracht^[11]. YOLO hat sich zum Beispiel zu einem zentralen Echtzeit-Objekterkennungssystem entwickelt, insbesondere in Bereichen wie Robotik, autonomes Fahren und Videoüberwachung^[12].

Die Einführung solcher Systeme in industriellen Umgebungen wird jedoch durch das oben beschriebene Datenproblem erschwert. Das folgende Beispiel veranschaulicht, wie die in Abbildung 1 dargestellte Pipeline zur Generierung synthetischer Datensätze für die Objektklassifizierung und Lokalisierung bei der Montage von Baugruppen herangezogen werden kann. Als Grundlage dienen 3D-Modelle der Montageteile, die aus der CAD-Planung hervorgehen. Diese Modelle werden in einem vorgelagerten Schritt visuell aufbereitet, indem entsprechende Texturen aufgeprägt werden. Zusätzlich können werkstückspezifische, für den Montageprozess interessante Punkte (z.B. Greif- und Fügstellen) durch das Hinzufügen von Keypoints in den Modellen gekennzeichnet werden. Neben den Einzelteilen werden auch die Modelle der Baugruppe in unterschiedlichen Montageschritten hinterlegt, um eine automatische Überprüfung des Montagefortschritts zu ermöglichen.

Die visuellen Modelle werden in eine virtuelle Umgebung eingebettet, die Elemente wie Hintergründe,



Beleuchtungen, Störobjekte und virtuelle Kameras beinhaltet. Als Simulationsplattform dient Nvidia's Isaac Sim, das durch RTX-Raytracing fotorealistisches Rendering in Echtzeit ermöglicht ^[13]. Darüber hinaus bietet Isaac Sim Werkzeuge zur Domain-Randomisierung, was einen erfolgreichen Sim2Real-Transfer begünstigt. Die Domain-Randomisierung beinhaltet hier unter anderem die Veränderung der Unter- und Hintergrundtextur, Beleuchtungsintensität und Farbe, Störobjekte und Kamerawinkel. Ein Ausschnitt aus dem geränderten Datensatz ist in Abbildung 2 zu sehen.

Neben den Bildern werden auch die dazugehörigen Annotationen generiert. Die Annotationen enthalten die Ground-Truth-Informationen aus der Simulation und können direkt in dem für das Training erforderliche Format ausgegeben werden. Zur Klassifikation und Keypointerkennung wird hier ein YOLOv8-Modell verwendet. Die Annotationen beinhalten Informationen über Objektklassen sowie die Position der Bounding Boxen und Keypoints in Pixelkoordinaten. Das mit synthetischen Daten trainierte YOLOv8-Modell lässt sich unmittelbar auf reale Baugruppen anwenden, wodurch der Aufwand für die manuelle Erzeugung von Daten vollständig entfällt. Das trainierte Modell erfüllt zwei Funktionen (siehe Abbildung 2): Erstens können Einzelteile und der Montagestatus der Baugruppe klassifiziert werden, um deren Vollständigkeit und die Einhaltung der korrekten Montage Reihenfolge zu überprüfen. Zweitens werden die vorab definierten Keypoints identifiziert, die mittels PnP-Algorithmen eine präzise Bestimmung der Position und Orientierung der Baugruppe im dreidimensionalen Raum erlauben (siehe Abbildung 2). Die gewonnenen Informationen können als Grundlage für die Prozessüberwachung, Steuerung und Qualitätskontrolle einer flexiblen roboterbasierten Montage dienen.

Automatisierte Qualitätsinspektion

Ein weiteres Beispiel ist die automatisierte Qualitätskontrolle zur Erkennung von Qualitätsmängeln. Derzeit wird ein Großteil der Prüfungen manuell durchgeführt, was einen hohen Aufwand erfordert ^[14]. Qualitätsprüfungen erfolgen entweder nach bestimmten Bearbeitungsschritten oder erst am Ende der Fertigung. Dadurch durchlaufen fehlerhafte Bauteile den

gesamten Wertschöpfungsprozess und werden erst in der finalen Qualitätsprüfung aussortiert. Laut der 10er-Regel erhöht ein nicht entdeckter Fehler in jeder Stufe der Wertschöpfung die Qualitätskosten, sodass eine möglichst frühzeitige Fehlererkennung aus wirtschaftlichen Gründen sinnvoll ist ^[15]. Eine automatisierte Qualitätsprüfung, die parallel zum Produktionsprozess abläuft, wäre daher wünschenswert. Sie würde die Durchlaufzeiten verkürzen, Personalkosten sparen und einen einheitlichen Qualitätsstandard gewährleisten ^[16].

Auch hier dient die in Abbildung 1 dargestellte Pipeline als Grundlage für die Erstellung von synthetischen Bildern von Qualitätsmängeln. Je nach Größe und Art von Qualitätsmängeln ist eine definierte Modellierung der Texturen von Bauteilen besonders wichtig, um sicherzustellen, dass das Modell zwischen einer Sollstruktur und entsprechenden Abweichungen zu unterscheiden lernt. Für die Modellierung der Fehler kommen unterschiedliche Methoden zum Einsatz. Der häufige Anwendungsfall von unerwünschten Kratzern auf Oberflächen lässt sich beispielsweise durch die Erstellung von CAD-Modellen von Kratzern oder durch die Überlagerung der Textur eines Kratzers realisieren. Der erste Fall ist dabei der für einen Ingenieur intuitivere Ansatz. Der zweite Ansatz kommt aus dem Bereich der 3D-Animation. In Programmen wie Blender wird dabei über verschiedene Verknüpfungen von Texturen der Kratzer in seiner Farbe und seinem unterschiedlichen Reflexionsverhalten simuliert. Dieser Ansatz ist für den nachfolgenden Schritt des Renderings weniger rechenintensiv. Für die Erstellung der Bilder werden verschiedene Parameter, wie beispielsweise die Lichtintensität sowie der Kamerawinkel randomisiert. Bezüglich des Kratzers werden Anzahl, Position, Form und Größe der Kratzer variiert. Die automatisierte Erstellung der Bilder kann in verschiedenen Programmen, z. B. im bereits erwähnten Isaac Sim von Nvidia oder in Blender, erfolgen. Für den gewählten Anwendungsfall wurde in einem Projekt untersucht, inwieweit die generierten synthetischen Daten ausreichen, Modelle zu trainieren, die zuverlässige Ergebnisse auf Realdaten liefern. Dazu wurden zunächst verschiedene Deep-Learning-Modelle ausgewählt und getestet. Zum einen wurden

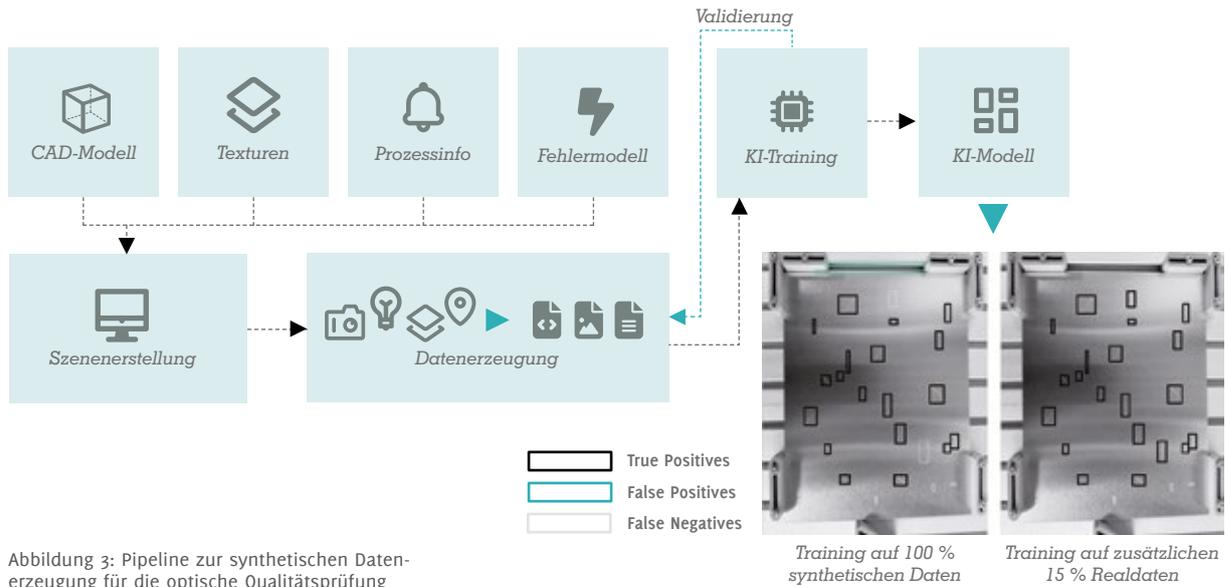


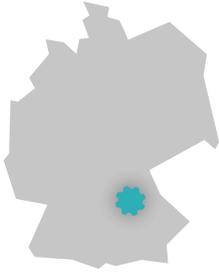
Abbildung 3: Pipeline zur synthetischen Datenerzeugung für die optische Qualitätsprüfung

zwei Versionen der YOLO-Modelle sowie ein Transformer-Modell (DTR) getestet werden. YOLOv9C zeigt die höchste Genauigkeit und wurde deswegen für weitere Untersuchungen ausgewählt.

Die ausreichende Authentizität der Trainingsdaten wurde anhand von zwei verschiedenen Trainingsdatensätzen validiert. Datensatz 1 umfasste ausschließlich synthetische Bilder mit einer unterschiedlichen Anzahl von Kratzern, während Datensatz 2 zusätzlich 15 % reale Bilder von vier verschiedenen Platten enthält. Datensatz 1 erzeugte einige falsch positive Ergebnisse, bei denen die T-geschlitzten Blechkanten fälschlicherweise als Defekte identifiziert wurden, was möglicherweise auf die unterschiedlichen Lichtverhältnisse zwischen simulierter und realer Umgebung zurückzuführen ist. Fünf Kratzer wurden übersehen. In Datensatz 2, der echte Bilder enthielt, wurden keine falsch positiven Ergebnisse beobachtet, aber drei von 24 Kratzern wurden übersehen. Diese Kratzer waren sehr fein und aus den derzeitigen Perspektiven schwer zu erkennen, was darauf hindeutet, dass eine weitere Optimierung der Beleuchtung und der Kamerawinkel die Erkennungsgenauigkeit verbessern könnte. Dennoch kann insgesamt subsumiert werden, dass sich die synthetischen Daten für das Training eignen.

Literatur

- [1] McKinsey&Company: Künstliche Intelligenz wird zum Wachstumsmotor für deutsche Industrie: <https://www.mckinsey.com/de/news/presse/kunstliche-intelligenz-wird-zum-wachstumsmotor-fur-deutsche-industrie>
- [2] Der Maschinenbau: Produktivitätssteigerungen von bis zu 50% durch KI: <https://der-maschinenbau.de/markt-trends-technik/produktivitaetssteigerungen-von-bis-zu-50-durch-ki/>
- [3] Melo, C.M. de, Torralba, A., Guibas, L., DiCarlo, J., Chellappa, R., Hodgins, J.: Next-generation deep learning based on simulators and synthetic data. Trends in cognitive sci-ences (2022)
- [4] Silva Peres, R., Guedes, M., Miranda, F., Barata, J., 2021. Simulation-Based Data Augmentation for ...Structural Adhesive With Deep Learning. IEEE Access.
- [5] Rožanec, J. M., Zajec, P., Trajkova, E., Šircelj, B., Brecelj, B., Novalija, I., Dam, P., Fortuna, B., & Mladenic, D. (2022). Towards a comprehensive visual quality inspection for industry 4.0*. IFAC-PapersOnLine, 55(10), 690-695. <http://dx.doi.org/10.1016/j.ifacol.2022.09.486>.
- [6] Kutzias, Damian, Claudia Dukino, and Jan-Paul Leuteritz. "Leitfaden zur Durchführung von KI-Projekten." Fraunhofer IAO, -1, 2023. <https://publica.fraunhofer.de/handle/publica/445679>.
- [7] O. Petrovic, D. L. D. Duarte and W. Herfs, „Generating Synthetic Data Using a Knowledge-based Framework for Autonomous Productions,“ 2023 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), Seattle, WA, USA, 2023, pp. 1086-1093
- [8] Sudhakar, S., Hanzelka, J., Bobillot, J., Randhavane, T., Joshi, N., Vineet, V.: Exploring the Sim2Real Gap using Digital Twins. In: 2023 IEEE/CVF International Conference on Computer Vision (ICCV), pp. 20361-20370. IEEE (2023)
- [9] Petrovic, O., Dassen, Y., Brecher, C.: Potenziale des Industrial Metaverse - Konvergenz von der Simulation bis zur Realität, 2023, <https://www.industrie-management.de/node/603>
- [10] Simeth, A., Kumar, A.A. & Plapper, P. Flexible and robust detection for assembly automation with YOLOv5: a case study on HMLV manufacturing line. J Intell Manuf (2024). <https://doi.org/10.1007/s10845-024-02411-5>
- [11] Zou, Z., Chen, K., Shi, Z., Guo, Y., Ye, J.: Object Detection in 20 Years: A Survey. In: Proceedings of the IEEE, Vol. 111, 2023, Nr. 3, p. 257-276
- [12] Ultralytics HUB: Ultralytics HUB. URL: <https://hub.ultralytics.com/home>
- [13] NVIDIA: What Is Isaac Sim? – Omniverse IsaacSim latest documentation. URL: <https://docs.omniverse.nvidia.com/isaacsim/latest/overview.html>
- [14] Rožanec, J. M., Zajec, P., Trajkova, E., Šircelj, B., Brecelj, B., Novalija, I., Dam, P., Fortuna, B., & Mladenic, D. (2022). Towards a comprehensive visual quality inspection for industry 4.0*. IFAC-PapersOnLine, 55(10), 690-695. <http://dx.doi.org/10.1016/j.ifacol.2022.09.486>.
- [15] Sixsigmablackbelt: Fehlerkosten 10er Regel Zehnerregel (Rule of ten): <https://www.sixsigmablackbelt.de/fehlerkosten-10er-regel-zehnerregel-rule-of-ten/>
- [16] El Azab, W., Cousin, S., 2021. Visual Inspection Practices of CleanedEquipment: Part I. <https://www.pda.org/pda-letter-portal/home/full-article/visual-inspection-practices-of-cleaned-equipment-part-i>



SYSTEMATISCHE DATENERFASSUNG UND BEWERTUNG DER DATENQUALITÄT

Nils Thielen (FAU Erlangen-Nürnberg, Lehrstuhl für Fertigungsautomatisierung und Produktionssystematik), Sven Meier (FAU Erlangen-Nürnberg, Lehrstuhl für Fertigungsautomatisierung und Produktionssystematik)

Eine systematische Bewertung der Datengrundlage und –qualität ermöglicht es, gezielt Verbesserungspotenziale und Bedarfe zum Nachrüsten von Sensorik zu identifizieren.

Die Bedeutung von Daten für den Einsatz von Künstlicher Intelligenz ist allgemein anerkannt. Da neben der Quantität der vorhandenen Daten viel mehr deren Qualität von entscheidender Bedeutung ist, sollte diese bereits vor der Umsetzung einer KI-Lösung bewertet und bei Bedarf verbessert werden. Auch unabhängig von einem potenziellen KI-Einsatz führt eine hohe Datenqualität zu einem Mehrwert, beispielsweise in Bezug auf statistische Methoden, Nachverfolgbarkeit und Vertrauenswürdigkeit gegenüber Partnern und Kunden. ^[1]

Für die Bewertung der Datenqualität lässt sich eine modifizierte Version der SIPOC-Matrix einsetzen, die auch als Werkzeug der statistischen Versuchsdurchführung, insbesondere in der Qualitätskontrolle, bereits lange Zeit etabliert ist. ^[3] Darüber ist es möglich, Datenquellen (Suppliers S) eine Reihe von Eingangsgrößen (Inputs I), wie Einstellparameter und den entsprechenden Prozessschritt (Processes P), zuzuordnen sowie daraus notwendige zu erfassende Ausgangsgrößen (Outputs O) und deren Verwertungsort (Customers C) abzuleiten. So kann zum einen überprüft werden, welche relevanten Daten bereits erfasst

werden, zum anderen können diesen Kenngrößen, wie etwa Vollständigkeit, Auflösung und Datentyp, zugeteilt werden. Aufbauend auf der Matrix kann man dann Bedarfe für das Nachrüsten von Sensorik und deren Priorisierung sowie Maßnahmen zur Verbesserung der Qualität vorhandenen Daten ableiten. ^[2]

Während dieses Vorgehen für einzelne Prozesse gut zu realisieren ist, wird der Vorgang bei der Betrachtung gesamter Fertigungslinie erschwert. Hier ist es im Regelfall unabdingbar, dass Produkte prozessübergreifend eindeutig zugeordnet werden können, um auch komplexe Wechselwirkungen von Parametern über mehrere Prozesse identifizieren zu können. Idealerweise wird dies über eindeutige IDs, die beispielsweise über einen RFID-Chip oder Barcode ausgelesen werden können. Eine Zuordnung über Zeitstempel oder Reihenfolge ist dahingehend deutlich fehleranfälliger. Auch eine Abfolge von Einzel- und Batchprozessen muss dabei berücksichtigt werden. ^[2]

Die ML-SIPOC-Matrix als Tool zur Bewertung von Daten

Die modifizierte SIPOC-Matrix für Maschinelles Lernen (ML-SIPOC-Matrix) bietet eine Möglichkeit, die Datengrundlage entsprechend zu bewerten. Die Matrix selbst ist dabei ein Tool der ML-SIPOC-Methodik, die im Detail von Meier et al. in ^[2] beschrieben wird. Die ML-SIPOC-Methodik lässt sich in sieben Schritte un-

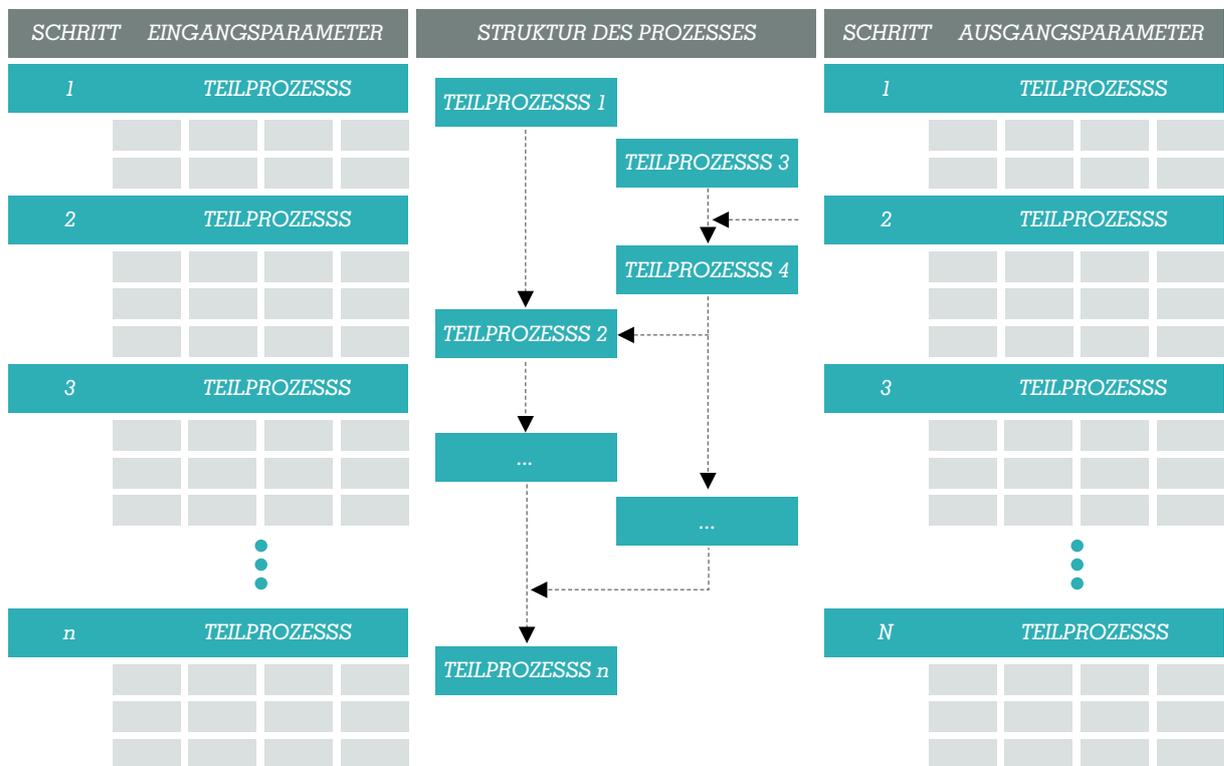
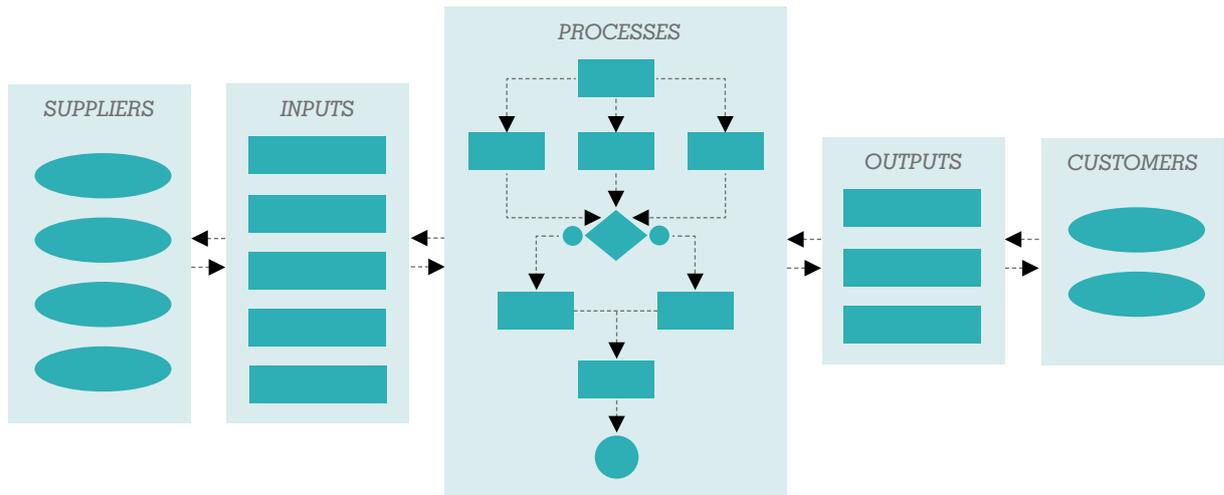


Abbildung 1: Schematische Darstellung der ML-SIPOC-Matrix in Anlehnung an [2]

terteilen, in denen die Matrix insbesondere in Schritt 5 und 7 Einsatz findet: Festlegung des Umfangs und Zielsystems, Analyse des Zielsystems, Definition von Data Governance und Daten-Architektur, Aufbau der Dateninfrastruktur, prozessweise Datenoptimierung, Datenintegration sowie die Validierung der Datenbasis. Die Methodik selbst lässt sich auch ohne Weiteres in etablierte Vorgehensweisen für datenbezogenen Projekte wie CRISP-DM^[4] integrieren.

Im fünften Schritt des ML-SIPOC-Prozessmodells werden die Hauptprozesse des Systems nacheinander analysiert. Diese Prozesse haben einen erheblichen

Einfluss auf die Datenbasis und sollten daher sorgfältig unter Einbeziehung der relevanten Prozessexperten analysiert werden. Die ML-SIPOC-Matrix wird für jeden Hauptprozess erstellt und jeder wichtige Parameter wird einzeln untersucht. Die Matrix ist schematisch in Abbildung 1 dargestellt.

Um eine effektive Vorgehensweise sicherzustellen, wird vorgeschlagen, regelmäßige Workshops abzuhalten, in denen alle Datenquellen und Informationsflüsse mit Prozessexperten und Data Scientists besprochen werden. Dabei werden sowohl strukturierte Daten als auch unstrukturierte Daten wie Bilder oder Prozess-



kurven berücksichtigt, deren Relevanz und Qualität zunächst als Ganzes bewertet werden sollte.

Zunächst wird der Hauptprozess analysiert und seine Struktur dokumentiert. Dazu wird der Prozess in einzelne Teilprozesse unterteilt, und die generierten Datenflüsse werden, sofern verfügbar, dargestellt. Diese Teilprozesse werden in einem Flussdiagramm dargestellt, um die Abfolge aller Schritte zu visualisieren. Es ist wichtig, die Daten so detailliert wie möglich zu erfassen, unabhängig davon, ob sie zum Zeitpunkt der Analyse bereits erfasst werden oder ob ihnen Relevanz zugeschrieben wird. Für die Datenanalyse sollten Prozess- und KI-Experten ein Schema entwickeln, das alle relevanten Eigenschaften zur Datenverarbeitung und Modellierung umfasst, wie etwa Datentypen und statistische Merkmale. Die ML-SIPOC-Matrix dient hier als Werkzeug zur Dokumentation und Nachverfolgung aller Datenquellen. Es sollten alle verfügbaren Daten integriert werden, die potenziell Einfluss auf die Zielvariablen haben könnten. Häufig umfasst dies strukturierte Daten, wie sie in Manufacturing Execution Systems (MES) zu finden sind. Der Daten- und Parameterauswahlprozess sollte hier jedoch flexibel erweiterbar sein, um neue Erkenntnisse in späteren Analysephasen berücksichtigen zu können. Auch spezifische Merkmale aus unstrukturierten Daten, wie Formen in Bildern, können genutzt werden, um deren Informationsgehalt und Relevanz vorab abzuschätzen. Die Diskussion mit verschiedenen Stakeholdern ist dabei essenziell, um eine umfassende Sicht auf die Parameter und deren Auswirkungen auf die Zielvariablen zu erhalten. Weiterhin können Metriken und Kennwerte helfen, Aspekte wie Vollständigkeit, Konsistenz, Zugänglichkeit, Einzigartigkeit, Zuverlässigkeit und Integrität zu bewerten. Es ist ebenfalls wichtig, Parameter zu identifizieren, die potenziellen Einfluss auf die Zielvariablen haben, aber derzeit nicht in der Prozess- und Qualitätsanalyse enthalten sind. Hierfür können bewährte Methoden wie das Ishikawa-Diagramm genutzt werden. Darüber hinaus könnten Experimente oder Pilotstudien nach der Design-of-

Experiments-(DoE)-Methodik durchgeführt werden, um den Einfluss potenziell relevanter Parameter zu testen. Diese Methoden helfen, besonders in unsicheren Szenarien, Schlüsselfaktoren zu identifizieren. In der laufenden Produktion ist dies jedoch häufig nicht möglich.

Nach der Analyse der Eingabe- und Ausgabeparameter wird angestrebt, erkannte Diskrepanzen zu beheben und die Datenqualität bestehender Parameter zu optimieren. Zudem sollen potenziell relevante Parameter, die derzeit nicht erfasst werden, durch geeignete Sensorik oder andere Maßnahmen integriert werden. Hier bietet es sich ebenfalls an, Nachrüstbedarf zu priorisieren und darauf aufbauend konkrete Maßnahmen, Zuständigkeiten und Zeitpläne sowie ein System zur regelmäßigen Überprüfung der Wirksamkeit jeder Maßnahme zu etablieren. Eine kontinuierliche Überwachung, Feedback durch Experten und Bereitstellung und Visualisierung bereits erfasster Daten, beispielsweise mittels Dashboards, erleichtern die erfolgreiche Umsetzung.

Diese Schritte gewährleisten eine kontinuierliche Verbesserung der Datenqualität und der Integration einflussreicher Parameter, um die Zuverlässigkeit und Aussagekraft der Analyse zu maximieren.

Umsetzung anhand eines Kontaktierprozesses in der Sensorfertigung

Im folgenden Abschnitt wird die Umsetzung der ML-SIPOC-Matrix im Rahmen der ML-SIPOC-Methodik zur Realisierung eines qualitativ hochwertigen Datensatzes für ein industrielles KI-Projekt in der Automobilbranche vorgestellt. Die Fallstudie, die im Detail ebenfalls in^[2] beschrieben wird, konzentriert sich auf Datenanalyse und prädiktive Qualitätsanalysen in einer mehrstufigen Produktionslinie für Sensoren. Eine sorgfältige Abwägung von Zeit- und Kostenerwägungen ist dabei entscheidend.



Die neue Sensorgeneration bietet trotz ähnlicher Herstellungsverfahren eine höhere Auflösung, was engere Toleranzen erfordert und die Serienproduktion komplexer macht. Die Qualitätsparameter der End-of-Line-Prüfung weisen innerhalb dieser engen Grenzen erhebliche Schwankungen auf, was zu Unsicherheiten in der Prozessfähigkeit führt. Ziel einer angestrebten KI-Lösung ist es, neue Erkenntnisse über die Fertigungsprozesse zu gewinnen, die für die Optimierung der Serienproduktion entscheidend sind.

Die Einführung der ML-SIPOC-Methodik zielte in diesem Kontext auf die Bewältigung diverser datenbezogene Herausforderungen ab: inkonsistente Datenbenennung, begrenzte Rückverfolgbarkeit, wachsende Datenmengen und isoliertes Wissen der Beteiligten. Die ML-SIPOC-Methodik zielt darauf ab, diese Herausforderungen zu bewältigen und eine stabilere und verlässlichere Datenbasis zu schaffen: unvollständiges Prozesswissen.

Schritt 1: Festlegung des Umfangs und des Zielsystems

Das Projektziel war es, die Beherrschbarkeit und das Verständnis der Einflussfaktoren in der Produktionslinie zu verbessern, um ein prädiktives Modell für die Sensorqualität zu entwickeln. Darauf folgende Zielsetzungen umfassen die Entwicklung eines KI-Modells, das parallel zu den bestehenden Prozessen läuft, um Einblicke in die Produktionslinie zu gewinnen, sowie eine Entscheidungsfindung basierend auf Vorhersagen, um fehlerhafte Sensoren frühzeitig zu identifizieren und auszusortieren.

Schritt 2: Analyse des Zielsystems

In der zweiten Phase wurde eine eingehende Untersuchung der mehrstufigen Sensor-Montagelinie durchgeführt, um die zugrunde liegenden Prozesse zu verstehen. Ein umfassendes Verständnis der Produkteigenschaften, der möglichen Ausfallmodi sowie der komplexen Fertigungsprozesse war entscheidend, um Bereiche zu identifizieren, die die Qualität maßgeblich beeinflussen.

Schritt 3: Definition von Data Governance und Daten-Architektur

Die Formulierung und Umsetzung einer Data-Governance-Strategie für die Sensorproduktion erwies sich als komplexe, aber wesentliche Aufgabe. Die Standardisierung der Datenformate, die Einführung eines leicht zugänglichen Datenkatalogs und strenge Zugriffskontrollen waren entscheidende Maßnahmen. Die Datenarchitektur wurde an die unterschiedlichen Datentypen angepasst, wobei eine relationale Datenbank für strukturierte Daten und eine NoSQL-Datenbank für semistrukturierte Daten genutzt wurde. Die Architektur wurde modular und skalierbar gestaltet, um eine zukünftige Erweiterung auf andere Produktionslinien zu ermöglichen.

Schritt 4: Aufbau der Dateninfrastruktur

Eine robuste und sichere Dateninfrastruktur wurde aufgebaut, einschließlich eines zentralen Datenspeichers (Data Lake) zur Handhabung vielfältiger Datentypen. Die Integration von Echtzeit-Datenströmen ermöglichte eine sofortige Analyse und schnelle Reaktion auf Anomalien im Produktionsprozess. Sicherheitsmaßnahmen wie Datenverschlüsselung und Zugriffskontrollen wurden implementiert, um die Daten vor Bedrohungen zu schützen.

Schritt 5: Prozessweise Datenoptimierung

Am Beispiel des Kontaktierungsprozesses, einer Laserlötoperation, wurde die Wirksamkeit der prozessweisen Datenoptimierung verdeutlicht. Ziel war es, durch eine detaillierte Analyse und Dokumentation des Prozesses Ineffizienzen und Datenmängel in Echtzeit zu identifizieren. Dies umfasst die Strukturierung des Kontaktierungsprozesses sowie eine Input- und Output-Analyse. Die entsprechenden Informationen werden mit der ML-SIPOC-Matrix erfasst und in Schritt 7 ausgewertet.

Schritt 6: Datenintegration

In der Phase der Datenintegration wurden Daten aus verschiedenen Quellen entlang der mehrstufigen Sensorproduktion zu einem einheitlichen Datensatz zu-



INPUT-ANALYSE DES KONTAKTIERPROZESSES				
#	SUPPLIER DES PARAMETERS	INPUT-PARAMETER	PARAMETER-TYP	KOMMENTAR
	Prozess 3 — LSR	Gehäuse	Einzigartige ID	...
	Supplier Pin	Pin	Batch-ID	
	Supplier Wire	Wire	Batch-ID	
	...			
1	Dispensen der Lotpaste und AOI-Prüfung			
	HMI-Monitor	Anzahl Lötunkte	Konstant	...
	Mechanische Einstellung	Dispensdruck [bar]	Einstellparameter	
	Mechanische Einstellung	Hubgeschwindigkeit [mms]	Einstellparameter	
	...			
...	...			
12	Laserlöten und AOI-Prüfung			
	HMI-Monitor	Leistung Laser [W]	Einstellparameter	...
	HMI-Monitor	Dauer Vorheizung [s]	Fix Value	
	HMI-Monitor	Dauer Laserlöten [s]	Fix Value	
	...			

Abbildung 2: Exemplarische Input-Analyse eines Kontaktierprozesses mittels der ML-SIPOC-Matrix in Anlehnung an [2]

sammengeführt. Ein ETL-Tool (Extraktion, Transformation, Laden) wurde verwendet, um die verschiedenen Sensor-Datenformate zu harmonisieren und in einen kohärenten Datensatz zu überführen. Die Genauigkeit und Zuverlässigkeit der integrierten Daten wurde durch strenge Validierungsverfahren sichergestellt.

Schritt 7: Validierung der Datenbasis

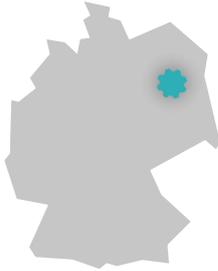
Nach Abschluss der detaillierten Analysen der Hauptprozesse und der Integration wichtiger Parameter konnten erste Datenanalysen Indikatoren für weitere fehlende wichtige Parameter identifizieren. Durch die Anwendung der ML-SIPOC-Matrix konnten diese Parameter systematisch abgeleitet und in die Datenbasis integriert werden. Exemplarischer Inhalt der in Abbildung 1 aufgeführten ML-SIPOC-Matrix ist in Abbildung 2 zu sehen.

Die Datenqualität verbesserte sich deutlich und die Verfügbarkeit der Daten stieg auf durchschnittlich 98 % in Echtzeit. Die ML-SIPOC-Methodik erwies sich als wirkungsvolles Instrument zur Bewältigung der Herausforderungen in der industriellen Sensorpro-

duktion. Durch die Schaffung einer soliden Datenbasis wurden nicht nur die Qualität und die Verfügbarkeit der Daten verbessert, sondern auch die Grundlage für eine erfolgreiche prädiktive Analyse und Optimierung gelegt. Die Methodik bietet einen systematischen Ansatz zur kontinuierlichen Verbesserung und ist auf andere Produktionslinien übertragbar.

Literatur

- [1] ESCOBAR, C.A., M.E. MCGOVERN und R. MORALES-MENENDEZ. Quality 4.0: a review of big data challenges in manufacturing [online]. Journal of Intelligent Manufacturing, 2021, 32(8), S. 2319-2334. ISSN 0956-5515. Verfügbar unter: doi:10.1007/s10845-021-01765-4
- [2] MEIER, S., S. KLARMANN, N. THIELEN, C. PFEFFERER, M. KUHN und J. FRANKE. A process model for systematically setting up the data basis for data-driven projects in manufacturing [online]. Journal of Manufacturing Systems, 2023, 71, S. 1-19. ISSN 02786125. Verfügbar unter: doi:10.1016/j.jmsy.2023.08.024
- [3] DAVIM, J.P. Design of Experiments in Production Engineering. Cham: Springer International Publishing, 2016. ISBN 978-3-319-23837-1
- [4] SCHRÖER, C., F. KRUSE und J.M. GÓMEZ. A Systematic Literature Review on Applying CRISP-DM Process Model [online]. Procedia Computer Science, 2021, 181, S. 526-534. ISSN 18770509. Verfügbar unter: doi:10.1016/j.procs.2021.01.199



LABELING MULTI- MODALER PROZESSDATEN BEIM 3D-DRAHTAUFTRAGS- SCHWEISSEN

Tobias Westphal (Technische Universität Berlin), Adam Altenbuchner (Technische Universität Berlin), Aashirwad Parasar (Gefertec), Jan Guhl (Gestalt Automation), Erik Sörqvist (Technische Universität Berlin), Raz Flieshman (Technische Universität Berlin)

Labeling multimodaler Prozessdaten beim 3D-Drahtauftragungsschweißen ermöglicht die Entwicklung von KI-Modellen, die qualitätsrelevante Prozessmerkmale bereits während des Fertigungsprozesses aus den gemessenen Prozessgrößen erkennen können.

Lichtbogendrahtauftragungsschweißen (engl.: Wire Arc Additive Manufacturing, WAAM) ist ein additives Fertigungsverfahren, das den schichtweisen Druck von 3D-Strukturen aus Metalldraht erlaubt. Dabei kombiniert WAAM traditionelle Schweißtechnologie und moderne Techniken zur additiven Fertigung. Der Metalldraht wird in einen elektrischen Lichtbogen gespeist, um ein Schmelzbad zu bilden, das über Achsbewegungen präzise in die gewünschte Form gebracht wird. WAAM profitiert von einer hohen Aufbaurrate und trägt dazu bei den Materialausschuss gegenüber herkömmlichen, subtraktiven Verfahren erheblich zu reduzieren. WAAM ist äußerst kosteneffizient, da es konventionellen Schweißdraht und gängige Schweißausrüstung anstelle spezieller Metallpulver und Laser verwendet, wodurch der ökologische Fußabdruck reduziert wird. Das Verfahren ist besonders vorteilhaft für die Herstellung großer Metallkomponenten mit komplexen Bauteilgeometrien und kundenspezifischer Teile, die mit gewöhnlichen Herstellungsverfahren nicht oder nur schwer zu realisieren sind. WAAM

kann auch bei der Reparatur und Wartung von hochwertigen Komponenten mit einem weiten Spektrum von Metallen, wie Stahl-, Titan-, Aluminium- und Nickellegierungen eingesetzt werden. Dabei ist WAAM für verschiedenste industrielle Anwendungen, wie die Luft- und Raumfahrt, die Automobilindustrie, die Schifffahrt, die Öl- und Gasindustrie, dem Bauwesen und weiteren Anwendungsfeldern, geeignet.

Merkmale in den Daten

Schweißspritzer und Lichtbogen. Rechts oben: Prozessbild mit Segmentierungen. Erläuterung der einzelnen Merkmale erfolgt im Text. Rechts Unten: Hochfrequentes Strom-/Spannungssignal während des Schweißens und hervorgehobene Puls- und Kurzschlussphasen zur Qualitätsbeurteilung des aktuellen Prozesses.

Insgesamt werden gleichzeitig über 20 verschiedene Prozessparameter in unterschiedlichen Datenraten vom 3D-Drucker aufgezeichnet. Einige kommen vom Achssystem, der Schweißstromquelle oder externen Sensoren. Zusätzlich besteht die Möglichkeit weitere Sensoren hinzuzufügen. Einige der einflussreichsten und aussagekräftigsten Parameter sind:

- Prozessvideos der Schweißkamera mit einer Takt rate von bis zu 50 Hz

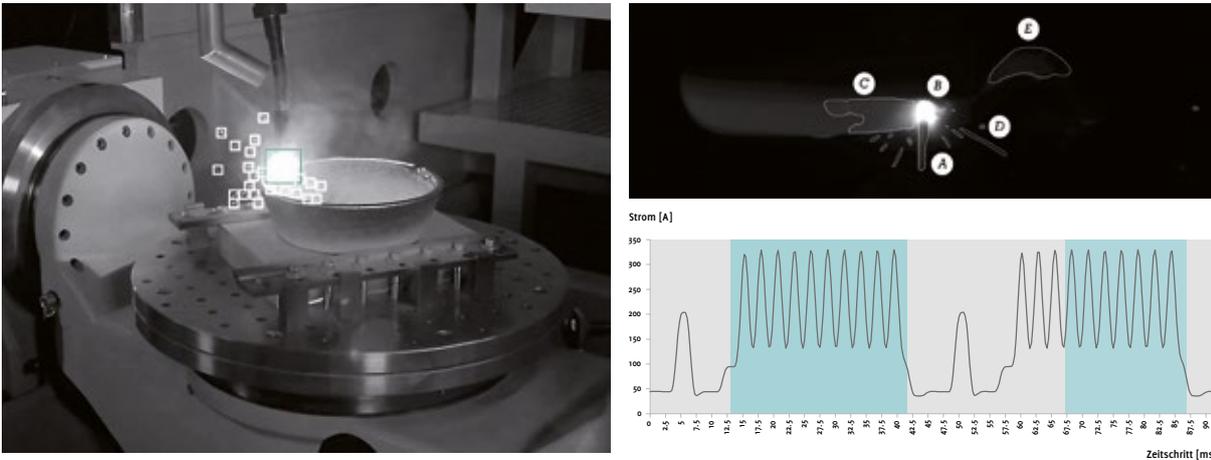


Abbildung 1: KI-basierte Überwachung eines 3D-Metalldruckprozesses. Links: Schweißprozess mit KI-basierter Erkennung zweier Prozessmerkmale, Schweißspritzer und Lichtbogen. Rechts oben: Prozessbild mit Segmentierungen. Erläuterung der einzelnen Merkmale erfolgt im Text. Rechts Unten: Hochfrequentes Strom-/Spannungssignal während des Schweißens und hervorgehobene Puls- und Kurzschlussphasen zur Qualitätsbeurteilung des aktuellen Prozesses.

- Stromstärke und Spannung, die mit einem Hall-Sensor in der Frequenz von 4 kHz gemessen werden
- Drahtvorschubgeschwindigkeit, die direkt von der Schweißstromquelle mit 10 Hz bereitgestellt wird
- Achspositionen der NC-Maschine in 125 Hz, die zur Korrelation von Prozessdaten mit Bauteilkoordinaten dient

Es lässt sich zwischen zwei Arten von Eingabedaten für KI-Anwendungen unterscheiden: Bild- und Sensordaten. Elektrische Messwerte, wie zum Beispiel Strom und Spannung, lassen sich dabei in direktem Zusammenhang mit zeitgleich erfassten Bildern interpretieren. In Bildern des WAAM-Prozesses lassen sich sechs Merkmale identifizieren, die für die Qualität des Prozesses von besonders hoher Bedeutung sind. **(A)** Ein wesentliches Merkmal ist die sichtbare Länge des, für den Schweißprozess benötigten, Metall-Drahts, der kontinuierlich aus der Düse gefördert wird. **(B)** Ein weiteres wichtiges Merkmal ist die Größe des Lichtbogens, der sich zwischen dem Draht und dem Werkstück bildet, sobald elektrischer Kontakt zwischen Draht und Werkstück besteht. **(C)** Hinzu kommt das Schmelzbad aus geschmolzenem Metall, das sich auf dem Werkstück formt und schnell abkühlt. Neben der Form ist hier vor allem die Länge von Bedeutung. **(D)** Ein weiteres entscheidendes Merkmal stellen Spritzer dar, die aus glühenden Metallteilen bestehen

und deren situationsbedingte Anzahl ein relevantes Kriterium für die Prozessqualität darstellen können. **(E)** Zuletzt kann auch das Auftreten von Rauch und die Überbelichtung der Bilder festgestellt werden. In den Strom- und Spannungsdaten des WAAM-Prozesses lassen sich verschiedene Phasen feststellen. Der zeitliche Verlauf dieser Daten lässt sich grob in die Kurzschluss- und die Puls-Phase unterteilen, die sich während des Schweißens abwechseln und je nach gegenwärtiger Prozesskonfiguration unterschiedliche Eigenschaften haben.

Um diese Prozessmerkmale nun mittels maschinellen Lernens oder Computer Vision wiederzuerkennen, werden Trainingsdaten benötigt, auf denen die relevanten und wiederzuerkennenden Daten markiert worden sind. Dieser Schritt wird Labeling oder Annotation genannt. Grundsätzlich richtet sich die Form der Annotation dabei nach der Art der wiederzuerkennenden Information. Es kann bei der KI-basierten Bildverarbeitung zwischen Klassifikation, Objekterkennung, semantischer Segmentierung und Instanzsegmentierung unterschieden werden. Klassifikation bezeichnet die Zuordnung eines Bildes zu einer von mehreren vorgegebenen Kategorien, dabei wird das gesamte Bild entsprechend zugeordnet. Eine Objekterkennung ist in der Lage, einen genaueren rechteckigen Bereich, um einzelne Objekte zu bestimmen, die sogenannten Bounding-Boxen. Beim Erstellen von



Trainingsdaten müssen ebendiese vorgegeben werden. Das bedeutet beispielsweise bei der Erkennung von Spritzern, die beim Lichtbogendrahtauftragschweißen auftreten können, dass jeder einzelne Spritzer mit einem Rechteck hervorgehoben werden muss. Sollen die Bereiche noch genauer eingegrenzt werden, so kommen Segmentierungsverfahren zum Einsatz, bei denen jedem einzelnen Bildpunkt, jedem Pixel, eine Klasse zugeordnet wird. Bei Schweißspritzern bedeutet dies eine pixelgenaue Unterscheidung in Spritzer und Hintergrund. Es lässt sich sagen, je genauer Merkmale in Bildern bestimmt werden sollen, desto größer ist auch der Aufwand zum Erstellen von Trainingsdaten.

Neben Bilddaten können auch andere Datenmodalitäten wie Zeitreihen, Textdaten, Audio- und Sprachaufzeichnungen sowie Tabellendaten, z.B. für Kun-

dengruppen in einer Datenbank, gelabelt werden. Für Zeitreihen kommen dabei häufig regelbasierte, statistische und ML-Verfahren zur Analyse und zum (semi-) automatischen Labeln zum Einsatz, aber auch ein manuelles Labeln ist möglich. Spezielle Zeitpunkte, an denen sich die statistischen Eigenschaften signifikant ändern, sogenannte Change-Points, oder zusammenhängende Intervalle, z.B. Prozessphasen in Sensordaten, können so gelabelt werden.

Integration von Expertenwissen

Prozessingenieure verfügen in der Regel über umfangreiche Erfahrungen, um Fehler in Fertigungsprozessen zu erkennen. Diese Fähigkeit kann durch kontinuierliche audiovisuelle Überwachung erlangt werden und ein erfahrener Schweißtechniker kann durch Inspektion der Schweißnahtoberfläche, Bewertung der Menge

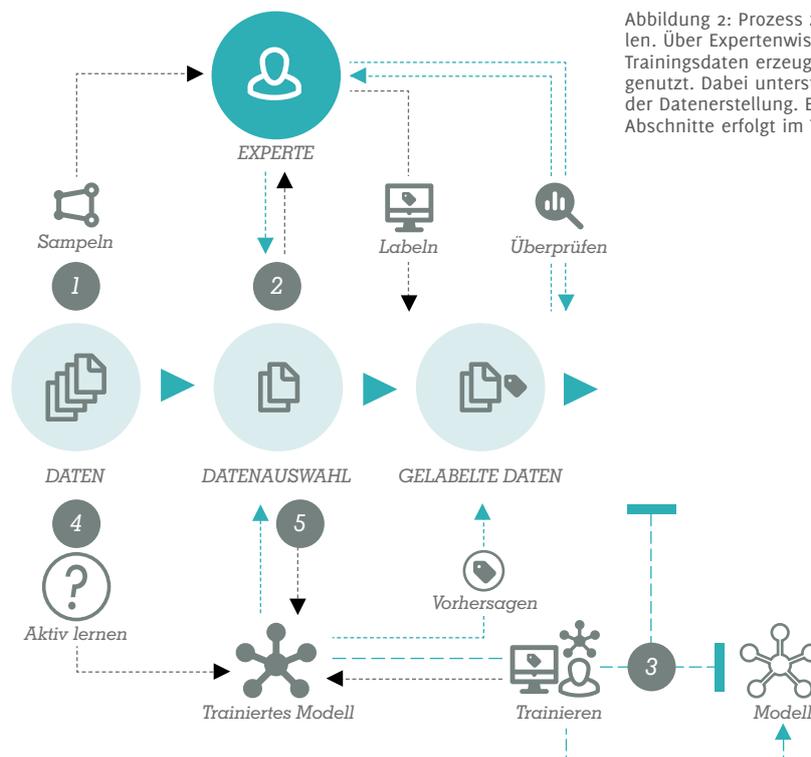


Abbildung 2: Prozess zum Erstellen von KI-Modellen. Über Expertenwissen werden kontinuierlich Trainingsdaten erzeugt und zum aktiven Lernen genutzt. Dabei unterstützen die Modelle auch bei der Datenerstellung. Erläuterung der einzelnen Abschnitte erfolgt im Text.



der erzeugten Spritzer oder sogar durch Auswertung der Intensität des Knackgeräuschs während des Prozesses feststellen, ob bestimmte Parameter angepasst werden müssen. Die Erkennung von Abweichungen in einem additiven Fertigungsprozess ist jedoch eine Herausforderung, da problematische Veränderungen im Prozessverhalten graduell über den Verlauf des Prozesses eintreten können. Folglich ist die Implementierung einer maschinellen Merkmalerkennung und einer schnellen Datenanalyse unerlässlich, um diese subtilen Prozessänderungen effektiv zu erkennen. Durch geeignete KI-Methoden ist es möglich hochfrequente und hochdimensionale Daten zu verarbeiten und Änderungen in Echtzeitdaten zu erkennen, noch bevor die Prozessqualität beeinflusst wird. Langfristig wird KI dazu in der Lage sein zu lernen, wie Prozessparameter angepasst werden müssen, um optimal auf diese Veränderungen zu reagieren.

Labeling

Die Überwachung eines Produktionsprozesses mit KI-Methoden bietet zahlreiche Vorteile, die zu einer verbesserten Effizienz, Qualität und Kosteneffektivität führen können. Führt man der KI die richtigen Trainingsdaten zu, so ist diese in der Lage Anomalien und Abweichungen im Produktionsprozess frühzeitig zu erkennen, bevor sie zu größeren Problemen führen. Dies hilft, die Produktqualität zu steigern und Ausschuss zu reduzieren. Insbesondere in Prozessen, deren Qualitätskontrolle mit aufwändigen oder zerstörenden Prüfmethoden durchgeführt wird, kann KI einen entscheidenden Beitrag zur Erhöhung der Produktionseffizienz leisten.

(3) Das Training von Künstlicher Intelligenz (KI) beim überwachten Lernen, insbesondere von Machine-Learning- und Deep-Learning-Modellen, erfordert gelabelte Daten, die als Grundlage für das Lernen und die Mustererkennung dienen. Die Label werden in diesem Zusammenhang auch als Ground-Truth (dt. Grundwahrheit) bezeichnet. Prozessexperten stellen durch

das Labeling ihr Wissen dem Einsatz in KI-Modellen zur Verfügung. Auch zur Validierung und beim Testen von KI-Modellen werden diese Label benötigt, um eine geringe Fehlerrate und hohe Genauigkeit nachzuweisen. Dabei gilt: Je besser die Modelle die zur Verfügung gestellten Daten abstrahieren sollen, desto größer und diverser muss der Trainingsdatensatz sein.

Der zeitliche Aufwand zum Labeln variiert, in Abhängigkeit von verschiedenen Faktoren, unter Umständen sehr stark. Das Klassifizieren von Bildern kann nur wenige Sekunden pro Bild in Anspruch nehmen, während beim Segmentieren von Bildbereichen, wie der pixelgenauen Markierung von Objekten, z.B. Schweißspritzern, mit mehrmaligem Hinein- und Herauszoomen ins Bild und der eigentlichen Markierung per Computermaus, auch mehrere Minuten pro Bild benötigt werden können. Zudem haben unter anderem die eingesetzte Labeling-Software, verfügbare Assistenzwerkzeuge sowie individuelle Leistung erheblichen Einfluss auf die Geschwindigkeit und Qualität des Labelns. Die erforderliche Menge an Daten, die beim sogenannten Transfer-Lernen pro Kategorie mehrere hundert Stück umfassen kann, verdeutlicht den immensen Datenbedarf und damit den Aufwand der Datenerstellung. Für das Vortrainieren der für das Transfer-Lernen benötigten Grundmodelle wird dabei sogar eine Stückzahl im niedrigen, zweistelligen Millionenbereich mit vielen Tausend verschiedenen Label-Kategorien verwendet. Es kann sich anbieten schon frühzeitig erste Modelle mit den eigenen Daten zu trainieren und diese zur Unterstützung beim Labeling einzusetzen.

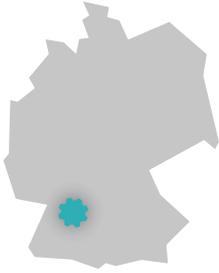
Zur Sicherstellung der Datenqualität können hybride Ansätze entwickelt werden, die menschliche Fachexpertise mit computerbasierter Massendatenverarbeitung kombinieren. **(5)** Dabei können Ergebnisse vorläufiger Modelle an Prozessexperten zur Überprüfung und Korrektur zurückgegeben werden, um die Datenqualität und -konsistenz zu verbessern und zusätzlich ein direktes Feedback über die benötigte Datenqualität und das durchgeführte Labeling zu lie-



fern. Der Einsatz von Ergebnissen vorläufiger Modelle kann den Aufwand beim Labeling reduzieren, indem nur Änderungen und Ergänzungen an den erhaltenen Labeln vorgenommen werden müssen. **(4)** Wenn ein vorläufiges Modell in einem iterativen Lernprozess basierend auf der Sicherheit seiner eigenen Vorhersagen die Auswahl der zu labelnden Daten übernimmt, spricht man von Aktivem Lernen. Durch das Labeling von Daten bei denen sich das Modell besonders unsicher ist, kann die Informationsdichte und damit die Effektivität der Label erhöht werden. **(1)** Durch die Kosinusähnlichkeit der vektoriellen Darstellungen von Bildern, den sogenannten Embeddings, lassen sich Bilder, die anderen sehr ähnlich sind, finden und entfernen, um eine geeignete und möglichst diverse Vorauswahl zu treffen.

(2) Labeln wird mittlerweile von einigen etablierten Werkzeugen ermöglicht, die sich in ihrer Lizenzierung, Benutzeroberfläche und den unterstützten Modalitäten unterscheidet. Häufig verwendet werden sind Audacity, CVAT, Doccano, Labelbox, Labelimg, Label Studio, LightTag, MATLAB, Prodigy, RectLabel, Roboflow, Supervisely, Tagtog und VGG Image Annotator. Diese Werkzeuge bieten oft Assistenzfunktionen wie vortrainierte Modelle, z.B. das Segment-Anything-Model (SAM), Aktives Lernen, Segmentierungs- und Change-Point-Detection-Algorithmen, die das Labeln erheblich beschleunigen können. Für das Labeln von Bildern des WAAM-Prozesses wird CVAT auf einem lokalen Server zur Verfügung gestellt, sodass die Bilder authentifiziert und verschlüsselt ohne die Beteiligung Dritter annotiert werden können. In den Zeitreihendaten von Strom und Spannung im Prozess können die CMT- und Puls-Phase, durch eine musterbasierte Ähnlichkeitssuche mit Mueens-Algorithm-For-Similarity-Search aus der Stumpy Software-Bibliothek für Python, semi-automatisch gelabelt werden.

6. Modellierung und Korrelation multimodaler Daten
Die gelabelten Bilddaten dienen als Input für KI-Modelle des maschinellen Sehens, die zur Prozessüberwachung, wie bei der Anomalieerkennung, eingesetzt werden. Für präzise Ergebnisse wird auf etablierte Modelle des maschinellen Sehens zurückgegriffen, wie die sogenannten YOLO-Modelle von Ultralytics oder SAM, Mask R-CNN und Detectron2 von Meta AI. Einmal trainiert, kann das Modell im Inferenzmodus Objekte wie Spritzer, Schmelzbad, Lichtbogen, austretenden Draht, Rauch und Überbelichtung erkennen. Diese extrahierten Informationen können alleinstehend oder in Korrelation mit den extrahierten Merkmalen aus den zugehörigen Zeitreihen verwendet werden, um eine aussagekräftige Qualitätsprognose zu erstellen. Im Projekt KIKA-IPK werden Daten verschiedener Modalität und unterschiedlicher Frequenz genutzt, um Produktionsprozesse an den Beispielen der personalisierten Medizinherstellung und der Produktion von 3D-gedruckten Metallbauteilen, schon während der Prozesse zu überwachen. Je nach Art der Daten werden dabei spezifische Werkzeuge zum Labeling der Trainingsdaten, angepasste Methoden zur Auswertung der aktuellen Prozesswerte und variable Algorithmen für deren Korrelation und Vorhersage der Produktqualität eingesetzt. Mit der KI-basierten, maschinellen Inprozesskontrolle, können Mensch und Schweißprozess räumlich voneinander getrennt werden und damit auch die gesundheitlichen Auswirkungen auf den Menschen reduziert werden, bspw. der langfristige Einfluss des unvermeidbaren Schweißrauchs. Weiterhin ergeben sich durch die KI-basierte Prozessüberwachung zahlreiche Vorteile, die zu einer verbesserten Effizienz, Qualität und Kosteneffektivität führen können.



DRIFT-MANAGEMENT FÜR DATEN VON PRODUKTIONS- PROZESSEN

Jan Hermes, Constanze Hasterok (Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung IOSB)

Durch die Erkennung und Anpassung an Daten- und Konzeptdrifts können maschinelle Lernmodelle in industriellen Produktionsumgebungen effizienter und langlebiger eingesetzt werden.

Die Nutzung von maschinellem Lernen (ML) in der industriellen Produktion birgt enormes Potenzial, aber auch Herausforderungen. Eine der größten Herausforderungen ist die Erkennung und Anpassung an Daten- und Konzeptdrifts. Diese Drifts können die Leistung der ML-Modelle erheblich beeinträchtigen, da sie Änderungen in der Datenverteilung oder den zugrunde liegenden Prozessen widerspiegeln. Ursachen für solche Änderungen sind z.B. der Verschleiß von Werkzeugen, Änderungen der Maschinensollwerte, Änderungen der Sensoren (Rauschen, Auflösung, Kalibrierung, Alterungseffekte, usw.), Änderungen in Eingangsmaterialien, saisonale Effekte, sich ändernde persönliche Vorlieben und Verhaltensweisen des Bedienpersonals und Hardware- oder Softwarefehler. In diesem Artikel beleuchten wir, wie Drift-Management für die Daten von Produktionsprozessen eingesetzt wird, sodass ML-Modelle im langfristigen Betrieb eingesetzt werden können und obige Ursachen die Qualität der Modellvorhersage nicht beeinträchtigt.

Verborgene Variablen und deren Einflüsse

In unserer Darstellung eines cyber-physischen Systems, also z.B. eines Produktionssystems, sind Variablen durch Funktionen miteinander verbunden, die unveränderliche Gesetze des Systems repräsentieren, wie z.B. physikalische Gesetze. Diese Verbindungen werden in einem gerichteten Graphen dargestellt, der zeigt, wie verschiedene Variablen voneinander abhängen. Der Graph besteht aus beobachtbaren und verborgenen Variablen sowie den Funktionen, die diese Variablen verknüpfen.

Beispiel für einen gerichteten Graphen

In der untenstehenden Abbildung sehen wir ein Beispiel für einen solchen Graphen. Die Variablen v_0 bis v_{10} sind die Knoten des Graphen, und die Funktionen f_{10} bis f_7 stellen die Verknüpfungen dar. Die beobachtbaren Variablen sind farblich markiert (gelb für Merkmale, grün für Zielgrößen), während die verborgenen Variablen weiß dargestellt sind.

Beobachtbare Variablen sind solche, die direkt gemessen werden können, wie z.B. Temperatur, Druck oder Durchflussrate. Verborgene Variablen hingegen sind nicht direkt messbar und können interne Zustände

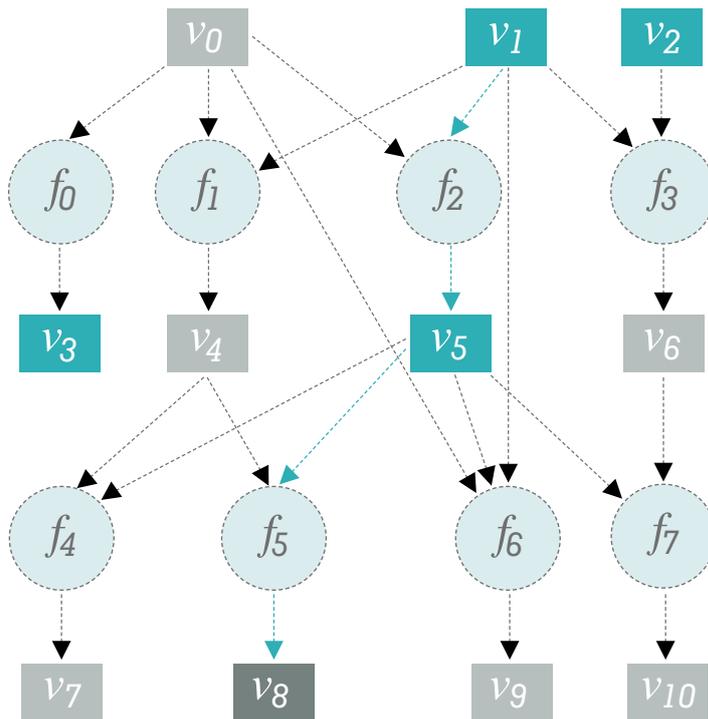


Abbildung: Beispielhafte Darstellung von Prozessvariablen und ihrer Abhängigkeiten. Grüne Knoten sind Merkmale (Features) und dunkelgraue Knoten sind Zielgrößen (Targets) beim maschinellen Lernen.

Die grünen Kanten zeigen einen beispielhaften Pfad von einem Merkmal zu einer Zielgröße. Gestrichelte Knotengrenzen repräsentieren verborgene Variablen und Funktionen.

oder Umweltbedingungen umfassen, die nur indirekt erfasst werden können. Beispielsweise sind v_0 und v_4 verborgene Variablen, die durch die Funktionen f_1 und f_5 auf die Zielvariable v_8 Einfluss nehmen. v_1 ist eine beobachtbare Variable und beeinflusst direkt v_5 durch die Funktion f_2 . v_5 beeinflusst dann wiederum die Zielvariable v_8 .

Daten- und Konzeptdrift

In unserer Darstellung eines cyber-physischen Systems können zwei Hauptarten von Drifts definiert werden, die in einem Lernproblem auftreten können:

Datendrift:

Ein Datendrift tritt auf, wenn sich eine oder mehrere verborgene Variablen ändern, die einen Einfluss auf die beobachtbaren Merkmale haben. Diese Änderungen führen dazu, dass die Verteilung der beobachtbaren Merkmale über die Zeit variiert.

Beispiel: Eine Änderung in der verborgenen Variable v_0 könnte die beobachtbare Variable v_5 beeinflussen, was zu einer Veränderung in deren Verteilung führt. Ein Beispiel für eine beobachtbare Variable könnte die Temperatur in einem Produktionsprozess sein, während eine verborgene Variable eine interne Maschinenabnutzung darstellt, die nicht direkt gemessen wird.

Konzeptdrift:

Ein Konzeptdrift tritt auf, wenn sich eine oder mehrere verborgene Variablen ändern, die einen Einfluss auf die Zielvariablen haben. Diese Änderungen beeinflussen die Beziehung zwischen den Merkmalen und den Zielvariablen.

Beispiel: Eine Änderung in der verborgenen Variable v_4 könnte die Zielvariable v_8 beeinflussen, was zu einer Änderung der Beziehung zwischen v_5 und v_8 führt. Hier könnte v_8 eine Qualitätskennzahl des Endprodukts sein, die durch versteckte Faktoren, wie die Zusammensetzung des Rohmaterials v_4 , beeinflusst wird.

Methoden zur Driftdetektion und -anpassung

Zur Erkennung von und Anpassung an Drifts gibt es zwei Hauptmethoden: performance-basierte und verteilungsbasierte Driftmethoden.

Performance-basierte Driftmethoden:

Diese Methoden setzen voraus, dass Daten verfügbar sind, in denen sowohl Messungen der Merkmale als auch Zielgrößen vorhanden sind. Die Modellleistung wird periodisch evaluiert, und bei einer Leistungsminderung wird ein Drift angenommen und das Modell anhand der neuen Datenbasis aktualisiert. Diese Methode eignet sich gut für die nachträgliche Analyse und

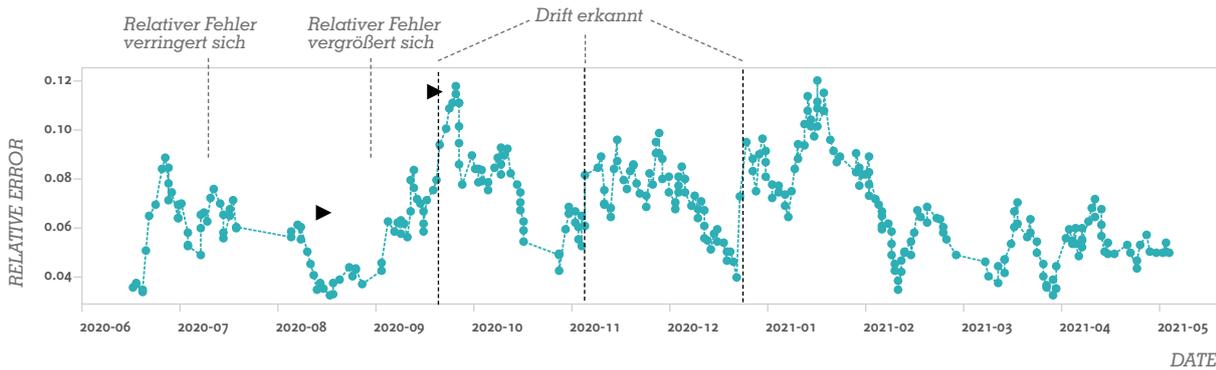


Abbildung: Entwicklung des Modellfehlers über die Zeit bei performance-basierter Driftdetektion und -anpassung

Anpassung, sobald die Messungen der Zielgrößen zur Verfügung stehen. Ein Beispiel ist das Szenario einer kontinuierlichen Fertigung, bei der anhand der Sensormesswerte im Prozess die Produktqualität durch ein ML-Modell vorhergesagt werden soll. Es werden regelmäßig Produktproben entnommen und Qualitätsmessungen im Labor unterzogen. Sobald neue Qualitätsmessungen zur Verfügung stehen, kann die Vorhersage des ML-Modells diesen gegenübergestellt werden und so die Modelleistung bewertet werden.

Verteilungsbasierte Driftmethoden:

Diese Methoden benötigen nur Messungen der Merkmale aber nicht der Zielgrößen. Sie erkennen Drifts in Echtzeit durch die Analyse der Datenverteilungen der Merkmale, was eine schnelle Anpassung ermöglicht. Dabei wird die Annahme getroffen, dass das ML-Modell nicht mehr präzise ist, sobald ein Drift aufgetreten ist. Diese Annahme kann jedoch in Einzelfällen nicht zutreffen, sodass eine unnötige oder sogar unvorteilhafte Anpassung vorgenommen wird.

Ein Beispielszenario für den vorteilhaften Einsatz von verteilungsbasierten Driftmethoden ist ein Produktionsprozess, welcher saisonalen Schwankungen unterliegt. Die gemessene Temperatur der Eingangsmaterialien ändert sich mit den Jahreszeiten. Die Verteilung der Temperaturen im Sommer ist daher anders als die im Winter und es wird ein Drift erkannt.

Realer Anwendungsfall: Fehlerentwicklung über die Zeit

In einem realen Anwendungsbeispiel eines industriellen Partners wurden die Schwankungen im relativen Fehler eines ML-Modells über die Zeit beobachtet. Es wurde also eine performance-basierte Driftmethode angewendet. Die folgende Grafik zeigt die Entwick-

lung des relativen Modellfehlers über die Zeit und die erkannten Drifts.

Beschreibung der Fehlerentwicklung:

- Relativer Fehler verringert sich: Phasen, in denen die Modelleistung besser wird.
- Relativer Fehler vergrößert sich: Phasen, in denen die Modelleistung schlechter wird.
- Drift erkannt: Zeitpunkte, an denen ein signifikanter Drift im Datenverhalten erkannt wurde, was zu notwendigen Modellanpassungen führte.

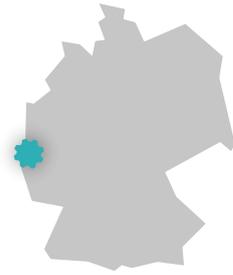
Praktische Hinweise zur Umsetzung

Bei der Implementierung von Drift-Management in Produktionsprozessen sind folgende Schritte essenziell:

1. Überwachung der Modelleistung: Regelmäßige Evaluation der Modelleistung zur frühzeitigen Erkennung von Drifts.
2. Verwendung geeigneter Frameworks: Einsatz von Frameworks, die sowohl performance-basierte als auch verteilungsbasierte Methoden unterstützen.
3. Automatisierung der Anpassung: Implementierung von Mechanismen zur automatischen Anpassung des Modells bei erkannten Drifts, um manuelle Eingriffe zu minimieren.

Fazit

Durch die Erkennung und Anpassung an Daten- und Konzeptdrifts können ML-Modelle in industriellen Produktionsumgebungen effizienter und langlebiger eingesetzt werden. Verborgene Variablen und ihre Einflüsse müssen verstanden und überwacht werden, um die Modelle präzise und anpassungsfähig zu halten. Die Anwendung der richtigen Drift-Detektionsmethoden ist entscheidend für den Erfolg von ML-Verfahren in dynamischen Umgebungen.



DATENMANAGEMENT IN DER PRODUKTIONS- TECHNIK

AUTOMATISIERTE KONTEXTUALISIERUNG UND ANALYSE AM BEISPIEL ZERSPANENDER WERKZEUGMASCHINEN

Vincent Lohrmann, Dr.-Ing. Marcel Fey, Prof. Dr.-Ing. Christian Brecher (Werkzeugmaschinenlabor WZL der RWTH Aachen)

Eine Grundlage für den Einsatz Künstlicher Intelligenz in der Produktionstechnik liegt in der automatisierten Kontextualisierung zum Datenmanagement.

Im Bereich der Produktionstechnik spielen die während der Fertigung generierten Daten eine zentrale Rolle für die Optimierung von Produkten und Produktionsprozessen. Moderne Werkzeugmaschinen sind mit zahlreichen Sensoren ausgestattet, die Daten mit hohen Abtastraten erfassen. Dies führt zu enormen Datenmengen. Neben den Herausforderungen bei der Speicherung dieser Daten aufgrund von Hardware- und Softwarebeschränkungen stellt die Implementierung sinnvoller Modelle zur Bewältigung und Analyse dieser Datenmengen eine wesentliche Herausforderung dar. Vor diesem Hintergrund wird ein Konzept zur Verarbeitung von Rohdaten aus Produktionsprozessen vorgestellt, mit dem diese Rohdaten automatisiert segmentiert und in einen Kontext gesetzt werden können. Mit diesem Ansatz zur Datenanalyse und -speicherung können unmittelbar nach Prozessende erste Erkenntnisse zur Optimierung von Produkten und Produktionsprozessen gewonnen werden. Aufbauend auf den segmentierten und kontextualisierten Daten können weitere Modelle entwickelt werden. Insbesondere für den Einsatz von Künstlicher Intelligenz und im Speziellen dem Machine Learning ermöglicht dieser Ansatz ein automatisiertes Labeling von Roh-

daten aus dem Produktionsprozess, um die Modelle trainieren zu können. Exemplarisch wird dieser Ansatz für Werkzeugmaschinen in der Zerspaltung vorgestellt; er ist jedoch auch auf andere Anwendungsfälle im Bereich der Produktionstechnik übertragbar.

Herausforderungen der Datenkontextualisierung

„Die wertvollste Ressource der Welt ist nicht mehr Öl, sondern Daten“ titelte der Economist bereits 2017^[1]. Neue Entwicklungen im Bereich der Künstlichen Intelligenz, insbesondere große Sprachmodelle wie „ChatGPT“ von OpenAI, haben gezeigt, welche mächtigen Werkzeuge durch eine geschickte Nutzung von Daten entstehen können. Ähnlich wie beim Öl liegt der wahre Wert von Daten nicht in ihrer Rohform, sondern in ihrer Veredelung zu höherwertigen Informationen, wenn sie in einen spezifischen Kontext gesetzt werden. In der heutigen Produktionsumgebung fallen durch automatisierte Produktionssysteme und computergesteuerte Maschinen bereits große Mengen an Rohdaten während des Fertigungsprozesses an. Diese Daten können zwar erfasst und gespeichert werden, jedoch stellt die Kontextualisierung, also beispielsweise die Zuordnung zu einzelnen Werkstücken, spezifischen Bearbeitungsabschnitten oder verwendeten Werkzeugen, eine Herausforderung dar. Die notwendigen Kontextinformationen sind oft an verschiedenen Stellen verteilt und erfordern die Implementierung komplexer

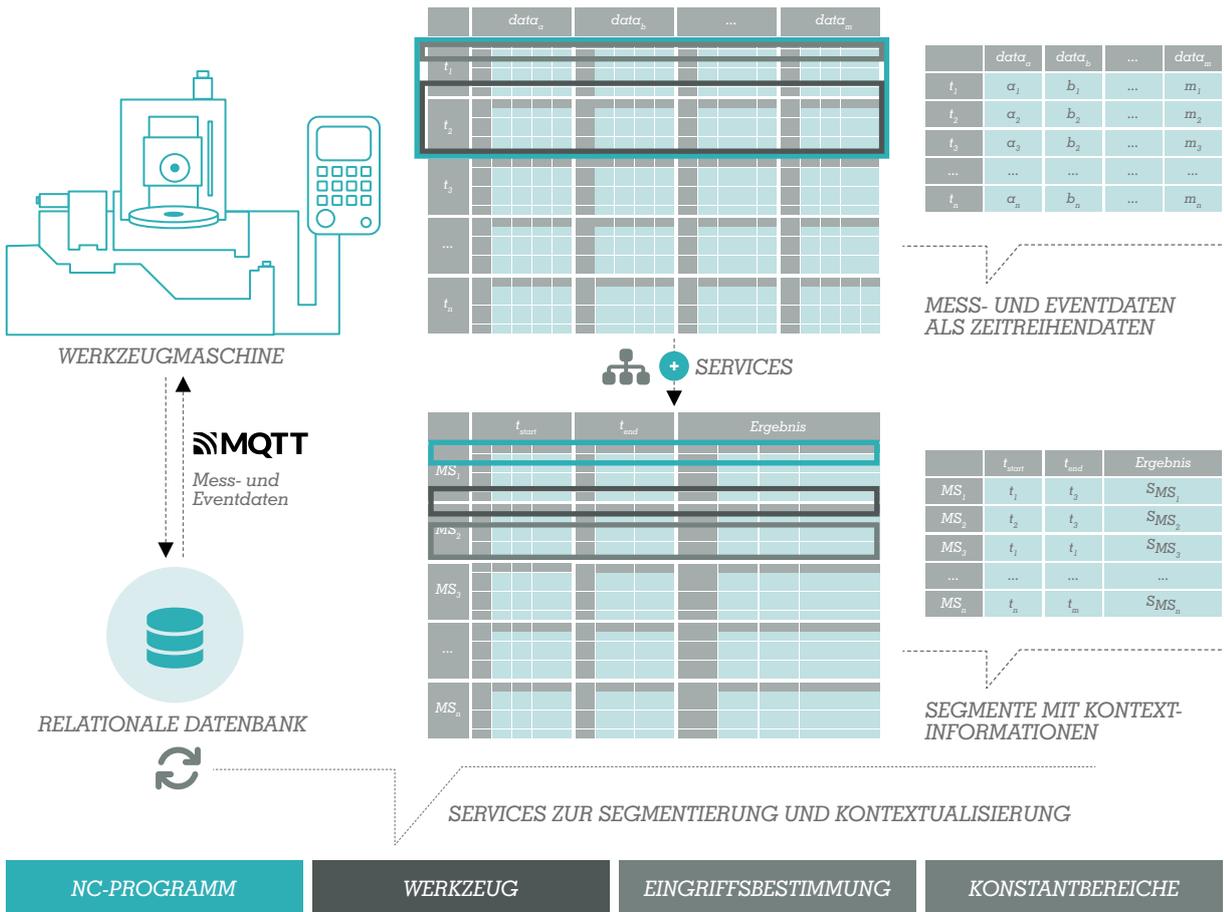


Abbildung 1 – Ansatz zur Kontextualisierung von Prozessdaten für eine Werkzeugmaschine

Schnittstellen oder sie sind nur im impliziten Wissen der Bediener und nicht digitalisiert vorhanden.

Umsetzung einer Umgebung zur kontextualisierten Datenerfassung und Datenmanagement

Um die beschriebene Problematik anzugehen, wurde am Werkzeugmaschinenlabor WZL der RWTH Aachen eine Umgebung entwickelt, in der Rohdaten aus der Produktion erfasst und gespeichert werden. Diese Daten können automatisiert kontextualisiert und sowohl Rohdaten als auch deren Kontext zur Verfügung gestellt werden. Dies erfolgt durch Visualisierung zur Datenexploration und Bereitstellung der Daten über entsprechende Schnittstellen, um die Entwicklung und das Training empirischer Modelle oder von KI-Modellen zu ermöglichen. Exemplarisch wurde der Ansatz für Werkzeugmaschinen aus dem Bereich der Zerspaltung umgesetzt. Schematisch ist der Ansatz in Abbildung 1 für eine Fräsmaschine dargestellt und wird im Folgenden beschrieben.

Zunächst werden die Rohdaten an der jeweiligen Maschine erfasst. Bei modernen Fräsmaschinen erfolgt dies über Schnittstellen zur numerischen Steuerung, wobei Informationen wie Achspositionen, Achsströme, Spindeldrehzahl und Spindelstrom sowie die aktive NC-Zeile und das aktive Werkzeug aus steuerungsinternen Daten im Lageregeltakt (in der Regel zwischen 500 und 1.000 Hz) erfasst werden. Zusätzlich können maschinenspezifische Ereignisse wie Programmstart, Werkzeugwechsel oder das Öffnen der Tür aufgezeichnet werden. Die hochfrequenten Mess- und Eventdaten werden über einen Edge-Computer von der Maschine erfasst und an einen zentralen MQTT-Broker auf einem Server weitergeleitet. Ergänzende Sensoren, beispielsweise zur Messung der Prozesskraft [2], können ebenfalls an der Maschine angebracht werden und ihre Mess- und Eventdaten an den zentralen Broker senden.

Serverseitig werden die Rohdaten von der Maschine abgerufen und in eine relationale Datenbank geschrieben. Hierfür werden zunächst die Informationen über



die Datenquellen, wie die numerische Steuerung einer Maschine oder zusätzliche externe Sensorik, in Verbindung mit dem zugehörigen MQTT-Topic angelegt und im Anschluss die auf dem MQTT-Broker eingehenden Daten automatisiert in das zugehörige Datenbankformat für Mess- beziehungsweise Eventdaten überführt. Im Wesentlichen liegen ab hier die Rohdaten aus der Werkzeugmaschine im Zeitreihenformat in der zentralen Datenbank ab. Um diese Rohdaten in einen Kontext zu setzen, werden im nächsten Schritt Segmente für die betrachtete Maschine und deren Rohdaten gebildet. Diese Segmente werden mit Start- und Endzeitpunkten sowie einem zugehörigen Ergebnis ebenfalls in der Datenbank gespeichert. Dafür läuft serverseitig ein Segmentierungsservice, der zyklisch mit der Datenbank kommuniziert und auf Trigger wartet, die eine Logik zur Berechnung von Segmenten auslösen. Ein Beispiel für einen solchen Service ist die Berechnung von Segmenten für die Dauer von NC-Programmen, die durch das Event „Programmstart“ von der Maschine ausgelöst wird. Der Startzeitpunkt ist der Zeitpunkt des Events, der Endzeitpunkt das folgende Event „Programmende“. Das Ergebnis der Segmentierung ist der Name des aktiven NC-Programms, der aus dem entsprechenden Event mit dem aktiven NC-Programm gelesen wird.

Durch das Eintragen eines solchen Segments für NC-Programme werden weitere Services getriggert, die innerhalb des NC-Programms weitere Berechnungen auf Basis der aufgezeichneten Rohdaten zur Segmentierung durchführen. So können auf Basis der Werkzeugnummer oder NC-Zeile Segmente für die jeweils aktiven Werkzeuge oder NC-Zeilen innerhalb eines NC-Programms gebildet werden. Zusätzlich wird über eine Schwellwertüberwachung des Hauptspindelstroms jede Bearbeitung in Bereiche eingeteilt, in denen das Werkzeug im Eingriff war oder nicht. Weitere detaillierte Ansätze zur Segmentierung von Fräsprozessen sind in [3] beschrieben.

Anwendung kontextualisierter Daten zur Datenexploration und Modellentwicklung

Der beschriebene Ansatz zur Kontextualisierung von Rohdaten durch automatisierte Datensegmentierung wurde an mehreren Fräsmaschinen im Werkzeugmaschinenlabor WZL der RWTH Aachen implementiert. Durch die Integration sowohl in die Werkstattfertigung als auch in Forschungsmaschinen wird eine große Menge an Rohdaten generiert. Diese Daten sind durch die beschriebene Kontextualisierung gut durchsuchbar für eine reine Datenexploration und bieten außerdem eine Grundlage sowohl für die Ableitung empirischer Zusammenhänge als auch für die Entwicklung von Modellen aus dem Bereich der Künstlichen Intelligenz. Durch die Implementierung einer Oberfläche zur Visualisierung können die Daten direkt an der Maschine oder maschinenübergreifend dargestellt und analysiert werden. Neue Erkenntnisse aus einer solchen Datenexploration können durch den modularen Aufbau der Servicearchitektur in weitere Algorithmen zur Segmentierung integriert werden. Zusätzlich können Segmente und die zugehörigen Rohdaten bei Bedarf exportiert und gezielt für das Training von KI-Modellen genutzt werden. Hervorzuheben ist außerdem, dass der beschriebene Ansatz nicht auf den Bereich der Werkzeugmaschinen beschränkt ist. Vielmehr kann der Ansatz, mit entsprechender Anpassung der Segmentierungsservices, auf verschiedene Produktionstechnologien, bei denen Zeitreihendaten anfallen, übertragen werden.

Literatur

- [1] THE ECONOMIST GROUP LIMITED: The world's most valuable resource is no longer oil, but data : Regulating the internet giants. In: The Economist 2017
- [2] BRECHER, C. ; ECKEL, H. ; MOTSCHKE, T. ; FEY, M. ; EPPLE, A.: Estimation of the virtual workpiece quality by the use of a spindle-integrated process force measurement. In: CIRP Annals 68 (2019), Nr. 1, S. 381-384. URL <https://www.sciencedirect.com/science/article/pii/S0007850619300460>
- [3] OCHEL, J. ; FEY, M. ; BRECHER, C.: Semantically Meaningful Segmentation of Milling Process Data. In: BEHRENS, Bernd-Arno; BROSIUS, Alexander; DROSSEL, Welf-Guntram; HINTZE, Wolfgang; IHLENFELDT, Steffen; NYHUIS, Peter (Hrsg.): Production at the Leading Edge of Technology. Cham : Springer International Publishing, 2022, S. 319-327



INTEGRATION VON SENSORDATENERFASSUNG, DATENANALYSE UND KI-FUNKTIONALITÄT

IN EIN MASCHINENAHES SOFTWAREKONZEPT ZUR ADAPTIVEN BEARBEITUNG

Dr. Jan Bremer (BCT), Dr. Markus Kogel-Hollacher (Precitec), Dr. Nick Brierley (diondo), Dr. Julian von der Ecken (Point8), Dr. Felix Bergunde (Resolto), Cedric Hauschopp (Fraunhofer ILT)

Am Beispiel des Laserauftragschweißens als Prozess mit komplexer Interaktion von Prozessparametern, Anlagentechnik, Bahnplanung und Bauteileigenschaften soll das Potenzial für die Umsetzung einer softwaregestützten, anlagennahen Benutzerunterstützung mittels automatisierter Prozessdatenaufnahme und -analyse sowie KI-basierter Parameterauswahl und Defektvorhersage zur Beurteilung der erwartbaren Bauteilqualität demonstriert werden.

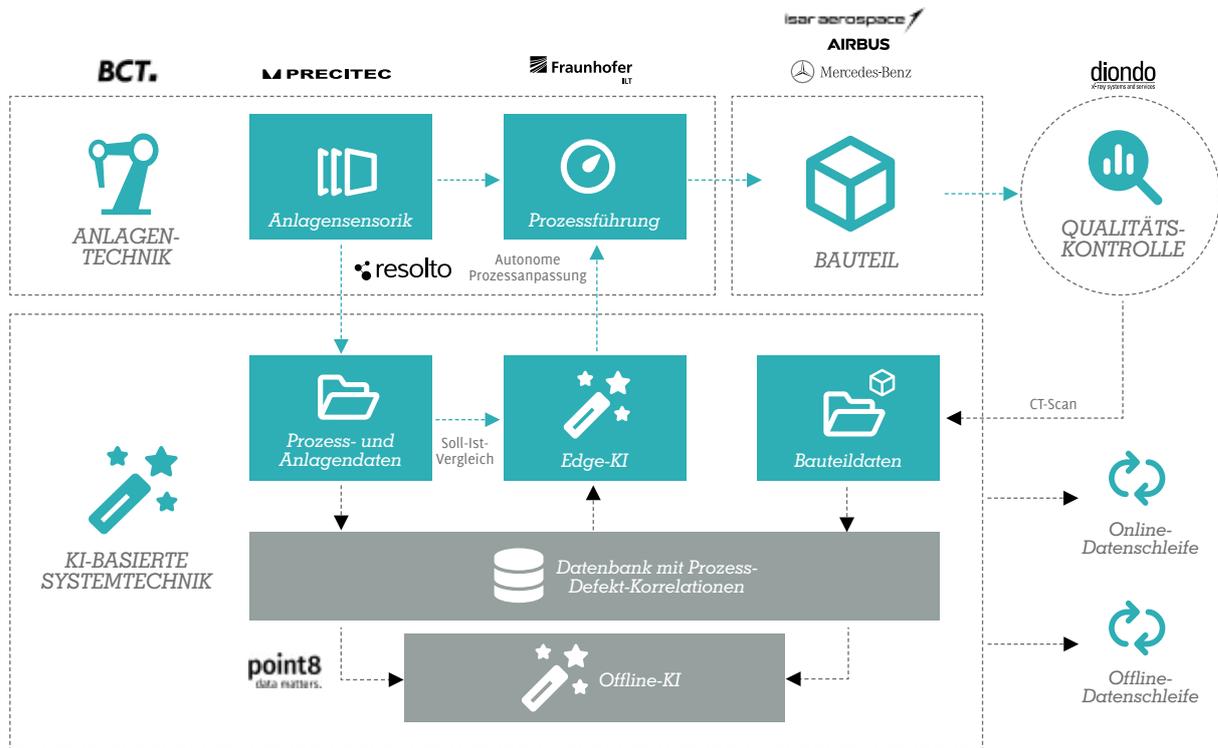
Das Gesamtziel des Forschungsvorhabens ProSLAM ist die Entwicklung einer KI-basierten, autonomen und lernenden Prozessplanung und -steuerung für additive Fertigungsverfahren, speziell das Laser Material Deposition (LMD) Verfahren. Dabei soll es vor allem um die Schaffung automatisierbarer Abläufe zur Erfassung relevanter Prozessdaten in hoher Qualität sowie Verfahren zum Training und Labeling von Prozessergebnissen auf Basis digitaler Abläufe zur dreidimensionalen Inspektion der resultierenden Bauteile mittels geometrischer Vermessung und CT-Analyse gehen.

Die Funktionalität dieser Systeme wird anhand industrieller Demonstratoren von Airbus, Mercedes Benz und Isar Aerospace validiert. Die übergeordneten Ziele des Projekts sind:

- Produktivitätssteigerung: Erhöhung der Gesamtproduktivität von LMD-basierten AM-Prozessen durch eine umfassende Prozessüberwachung und den Einsatz von KI-Methoden.
- Beschleunigung der Prozessentwicklung: Verkürzung der Entwicklungszeit durch daten- und KI-basierte Vorhersagen von Materialeigenschaften
- Verbesserte Materialausnutzung: Optimierung der Materialnutzung, Reduzierung von Ausschuss und Erhöhung der Anlagenverfügbarkeit
- Fehlervermeidung: Vorhersage und Vermeidung potenzieller Fehler (Risse, Anbindungsfehler und Poren) während des Prozesses durch KI-basierte Prozessführung

Das auf einer KI-gestützten Prozesssteuerung basierende Vorhaben in ProSLAM umfasst die Entwicklung und Validierung einer Steuerung, die auf umfangreichen Prozessüberwachungsdaten basiert. Diese Daten werden während des Prozesses, lagenweise intermittierend und nach dem Prozess erfasst. Zwei interagierende KIs werden entwickelt:

- Offline-KI: Korrelation von Prozessmessdaten mit Bauteil- und Werkstoffeigenschaften, basierend auf online und nach dem Prozess erhobenen Überwachungsdaten
- Online Edge-KI: Nutzung der Ergebnisse der Offline-KI und der online erfassten Prozessüberwachungsdaten zur lagenweisen Anpassung des Prozesses für einen fehlerfreien Aufbau



Erfassung prozessrelevanter Daten

Zur Erfassung von Datensätzen für die Entwicklung der prozessadaptiven KI wurde ein KUKA-Industrieroboter mit einem Datenerfassungssystem für LMD-Prozesse ausgestattet. Um mit der Sensorik auch koaxial zum Laserstrahl messen zu können, wurde eine neuartige Laserschweißoptik eingesetzt. Die Steuerung des Prozessablaufs der Roboteranlage sowie die Bahnprogrammierung, die In-situ-Geometriemessung der Bauteile und die Prozessdatenerfassung erfolgen dabei über ein integriertes anlagennahes Softwarekonzept.

Prozesse in der Lasermaterialbearbeitung haben gegenüber konkurrierenden Verfahren den Vorteil, dass sie vollständig berührungslos ablaufen. Zudem bedingt der Einsatz im Kontext der additiven Fertigung eine komplette Richtungsunabhängigkeit. Diese wesentlichen Randbedingungen waren die Grundlage für die Entwicklung des Laserbearbeitungskopfes im Projekt ProSLAM für die Precitec GmbH & Co. KG. In der Zusammenarbeit mit den Projektpartnern und Experten im Bereich der KI wurde ein Sensorkonzept erstellt, das ebenso berührungslos die wesentlichen

Messgrößen aus einem additiven Prozess extrahiert. In erster Hinsicht geht es um klassische Prozessparameter, wie Temperatur und Geometrie der Metallschmelze. Neu im Kontext der additiven Fertigung ist der Einsatz der OCT (Optische Kohärenztomographie) als Verfahren für die Messung der Spurhöhe.

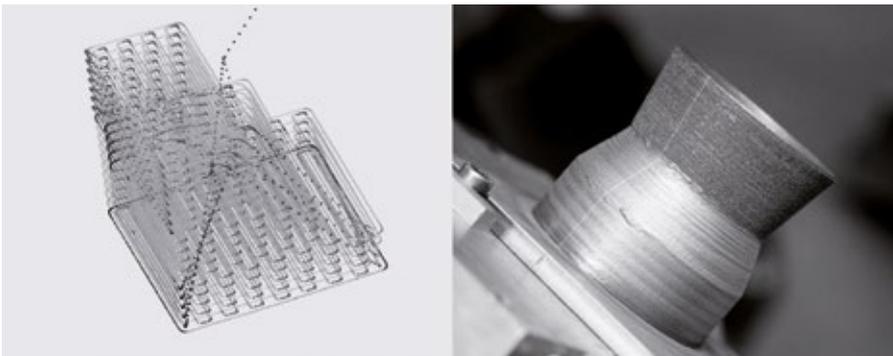
Die von der Firma Precitec entwickelte und bereitgestellte Lösung ist ein Bearbeitungskopf, der alle Sensorschnittstellen beinhaltet und alle generierten Daten an die übergeordnete Steuerung kommuniziert. Als Experte für Lasermaterialbearbeitungslösungen wurden die optomechanischen Anforderungen umgesetzt und in die Roboterzelle integriert.

Um berührungslose Messungen des Prozesses durchzuführen, wurde die Bearbeitungsoptik neben der OCT mit einer CMOS-Kamera, einem Pyrometer, einem Gasdurchflusssensor und einem Laserlinienscanner ausgestattet und die Sensorik seitens des Fraunhofer ILT auf den LMD-Prozess kalibriert. Durch die Verwendung eines Datenakquisitionssystems ist das synchronisierte Generieren von Daten zur Spur- und Schmelzbadgeometrie, Schmelzbadtemperatur und Bauteilgeometrie möglich.



Als Basis für die präzise, wiederholgenaue und benutzerfreundliche Durchführung des LMD-Prozesses ist die Einhaltung der geometrischen Grundparameter des Verfahrens von zentraler Bedeutung. So sollten der Arbeitsabstand sowie die Orientierung relativ zur Bauteiloberfläche möglichst konstant eingehalten werden. Die Programmierung der Schweißbahnen sollte dabei unter Berücksichtigung der realen Ist-Geometrie des Grundbauteils, Substrates oder letzten Stands des Druckfortschrittes erfolgen. Diese sogenannte adaptive Bahnplanung sowie die Durchführung der präzisen geometrischen Vermessung mittels anlagenintegrierter Laserlinienscanner-Technologie wird vom Projektpartner BCT Steuerungs- und DV-Systeme GmbH in Zusammenarbeit mit dem Fraunhofer ILT durchgeführt. Angepasste Kalibrierroutinen sowie diverse algorithmische Pipelines zur effizienten Verarbeitung der großen Datenmengen werden dabei im Rahmen des Projektes getestet, weiterentwickelt und validiert. Durch einen präzisen digitalen Zwilling der Anlagentechnik und Sensoren kann dabei ein geometrisch hochaufgelöster und akkurater digitaler Schatten des Bauteils in homogenen Koordinaten gemeinsam mit präzisen geometrischen Messwerten erzielt werden. Die Fusion der verschiedenen Anlagendaten, Sensorwerte sowie geometrischen Messwerte der verschiedenen Zustände des Bauteils und die Zusammenführung in eine gemeinsame benutzerfreundliche grafische Oberfläche ist Projektaufgabe der BCT Steuerungs- und DV-Systeme GmbH. Im Rahmen des

Projektes konnte die Entwicklung von Treibern zu geeigneten Sensoren direkt (z. B. Laserlinienscanner, Prozesskamera) und zu weiteren Sensoren über eine geeignete Datenerfassungseinheit erreicht werden. Die Sensoren werden dabei je nach Möglichkeit des individuellen Sensors zusammengeführt und mit den hochaufgelöst erfassten Anlagenpositionen fusioniert. So entsteht ein Datensatz mit bestmöglicher orts aufgelöster Qualität, der als Basis für die weiteren Arbeiten und gemeinsam mit externen Quellen wie der CT-Analyse und dem Training von KI-Modellen der Auswertung sowie der Prozessdiagnose dient. Die industrielle Computertomographie (CT) hat sich in den letzten Jahren zu einer wichtigen Prüftechnik zur zerstörungsfreien Bewertung der Qualität additiv gefertigter Metallbauteile entwickelt. Mit der CT können sowohl Fehler in Bauteilen, wie z. B. Poren, Risse und Anbindungsfehler, nachgewiesen, als auch eine Validierung der Bauteilgeometrie gegenüber der Konstruktion durchgeführt werden. Als Hersteller industrieller CT-Systeme verfügt die diondo GmbH über ein breites Spektrum hauseigener Anlagen, mit denen eine umfassende Charakterisierung der im Projekt gefertigten Testkörper und Bauteile, von der Mikrostruktur bis zur kompletten Bauteilgeometrie, durchgeführt wird. Zur automatisierten Auswertung der umfangreichen CT-Daten werden im Projekt unterschiedliche KI-basierte Methoden hinsichtlich ihrer Eignung erprobt und eingesetzt. Über intermittierende CT-Prüfungen im LMD-Prozess werden die Entstehung



Datenaufnahme und Beispiele: 3D-Pyrometerdaten aus LMD-Prozess and ProSLAM-Anlage (links), geometrische Vermessung LMD-Bauteil auf Roboteranlage (rechts)



und die Fortpflanzung von Fehlern nachverfolgt und darüber hinaus wichtige Informationen zur Prozessüberwachung gewonnen, die die Messdaten der Anlagensensorik komplementiert und validiert. Die CT-Datensätze werden dabei eingesetzt, um die gespeicherten Prozessdatensätze mit den detektierten Bauteildefekten ortsauflösend zu korrelieren.

Bauteil- und Datenanalyse

Um CT-Untersuchungen unter vergleichbaren Bedingungen durchführen zu können, hat die diondo GmbH im Projekt ein Verfahren entwickelt, das eine automatische Positionierung der Bauteile unter optimalen Prüfbedingungen ermöglicht. Hierzu wurde ein digitaler Zwilling der CT-Anlage unter Einsatz umfangreicher Methoden der Röntgensimulation realisiert. Das Tool erlaubt darüber hinaus eine bestmögliche Parametrisierung der CT-Messung, angepasst an die Geometrie und den Werkstoff des Prüfkörpers, wodurch Zeit und Kosten eingespart werden. Mithilfe der additiven Fertigung werden häufig Bauteile mit komplexen Geometrien gefertigt, deren präzise Halterung innerhalb des CT-Systems die Anwender vor teilweise große Herausforderungen stellt. Die diondo GmbH hat im Projekt einen Algorithmus realisiert, der mit dem digitalen Zwilling Konstruktionsmodelle berechnet, auf deren Grundlage eine automatische Fertigung individueller Bauteilhalter mittels additiver Fertigung möglich ist. Auf diese Weise ist eine robuste und reproduzierbare Fixierung der Probe im CT möglich, die für den intermittierenden Transport der LMD-Bauteile zwischen der LMD- und der CT-Anlage projektrelevant ist.

KI-Methoden halten Einzug in die unterschiedlichsten industriellen Anwendungsbereiche. Es ist im Rahmen der adaptiven Prozesssteuerung das Ziel, KI-basierte Assistenzsysteme zu schaffen, die den Bediener unterstützen. Dabei hängt die methodische Auswahl der KI stark von der Art der Daten und der jeweiligen Problemstellung ab.

Die Point 8 GmbH ist etablierter Dienstleister für die Konzeption und Umsetzung von KI-Projekten im Maschinen- und Anlagenbau sowie in der produzierenden Industrie. Im Forschungsprojekt ProSLAM hat sie sich methodisch sehr breit mit den verschiedenen Datenströmen auseinandergesetzt, um die relevantesten und erfolgversprechendsten KI-Methoden für die Umsetzung zu identifizieren. Besonderes Augenmerk wird dabei auf die Datenqualität und die statistische Aussagekraft der Daten gelegt, um aus Experimenten für die Trainingsdaten eine fundierte und reproduzierbare Datenbasis zu schaffen.

In der Analyse und methodischen Auswahl stellt die Definition und das Vorhandensein des Labels eine große Herausforderung. Denn es muss mit den Prozessparametern korrelieren und für das Training der Offline-KI verwendet werden können. Mögliche Größen sind dabei Informationen aus CT-Scans über Defekte, wie z. B. Poren, Live-Informationen über den aktuellen Arbeitsabstand (vgl. OCT) und auffällige Strahleigenschaften (Kameradaten). Auch der Erfahrungswert des Domänenexperten zur aktuellen Prozessstabilität ist ein wichtiges Kriterium, um die Ergebnisse direkt mit möglichen Handlungsempfehlungen für die Prozessführung für die Online-KI anzureichern. Neben dem Testen verschiedener Zielgrößen findet auch ein detailliertes Feature-Engineering (im Besonderen für die Bilddaten) statt.

Gegenwärtig wird die Offline-KI im Hinblick auf verschiedene Fehlerfälle entwickelt, sodass die Ergebnisse schließlich an die Online-KI zur Live-Prozessüberwachung übergeben werden können.

KI-Funktionalität

Ziel der Online-KI ist es, Abweichungen vom Normalzustand frühzeitig zu erkennen und durch ein Pausieren des Prozesses und/oder durch die Bereitstellung von Echtzeitinformationen und Handlungsempfehlungen für die/den Prozessexpertin/-experten den Prozess zu stabilisieren. Ein zentrales Element hierbei



ist das verwendete Edge Device (IPC), das CUDA- und GPU-fähig ist, um die Verarbeitung großer Datenströme zu parallelisieren und in nahezu Echtzeit zu ermöglichen. Hierdurch sollen zusätzliche Prozessunterbrechungen vermieden werden.

In Absprache mit BCT wurden Schnittstellen für die Datenübergabe definiert und beschlossen, das MQTT-Protokoll mit einer Protobuf-Serialisierung zu verwenden, um eine zuverlässige und schnelle Datenübertragung zu gewährleisten. MQTT bietet im LMD-Prozess eine effiziente Datenübertragung mit geringer Latenz, flexible Integration durch das Publish/Subscribe-Modell, hohe Zuverlässigkeit dank robustem Fehlermanagement und plattformunabhängige Interoperabilität. Protobuf ermöglicht eine effiziente und hochleistungsfähige Datenserialisierung, die kompakte und schnell verarbeitbare Datenformate erzeugt. Mit Protobuf können auch größere Datenpakete effizient übermittelt und gespeichert werden. Protobuf ist zudem plattformunabhängig und ermöglicht durch die stark typisierte Struktur eine flexible Integration und robuste Datenübertragung.

Die integrierten Sensoren umfassen verschiedene Datentypen, die es performant zu verarbeiten gilt. Insbesondere die CMOS-Bilder des Schmelzbades mit einer Auflösung von ca. 500 x 500 Pixeln und einer Frequenz von bis zu 160 Hz erzeugen einen großen Datenstrom. Hierzu wurden verschiedene Lasttests mit den Bildern durchgeführt, um potenziell relevante Features aus den Bildern performant zu erkennen und den Datenstrom zu minimieren. Ein wichtiger Schritt hierbei war die Implementierung eines Autoencoders, der in der Lage ist, die Bilder auf 15 bis 20 Werte zu reduzieren.

Weitere Features wie Pyrometerdaten sowie OCT-Werte werden mit bis zu 1 kHz aufgenommen und entweder aggregiert als Batch zu Verfügung gestellt oder auf feste Zeitstempel synchronisiert. Der Laser-Li-

nien-Scanner erzeugt nach Abschluss des Prozesses oder wahlweise auch lagenweise eine Punktwolke, die im PLY-Format übergeben wird.

Um die Prozessstabilität zu bewerten und Fehler sowie Abweichungen im Prozess zu identifizieren, wurden umfangreiche statistische Tests auf den bisherigen Proben durchgeführt. Insbesondere wurden Clusteranalysen verwendet, um Muster in den Daten zu erkennen und potenzielle Problemstellen frühzeitig zu identifizieren

Nutzung & Demonstration der adaptiven, KI-basierten Bearbeitung

Das entwickelte Datenerfassungssystem wird zur Generierung von Trainingsdaten in verschiedenen Prozessbereichen verwendet. Die Daten werden mit CT-Analysen von den geschweißten Bauteilen zusammengeführt und die Offline-KI auf verschiedene Prozessbedingungen trainiert.

Im Rahmen des Projektes ist die Zusammenführung sowohl der Bahnplanung, Anlagensimulation, der Prozessdaten sowie der Ergebnisse der KI-Analysen in einem homogenen User-Cockpit geplant, sodass die Ergebnisse möglichst anlagennah und benutzerfreundlich zur effizienten Unterstützung zur Verfügung stehen.

In diesem Kapitel werden die diversen Algorithmen und KI-Methoden vorgestellt. Convolutional Neural Networks, Causal AI, Reinforcement Learning: Es wird anhand von Praxisbeispielen erklären, was sich hinter diesen „Buzzwords“ versteckt. Das Kapitel beschreibt zahlreiche Methoden und Verfahren, die vielversprechende Lösungen für unterschiedliche Herausforderungen in der Produktion, wie etwa der Prozessüberwachung, Qualitätsvorhersage oder der Optimierung von Prozessparametern bieten. Die Einsatzfelder umspannen dabei zahlreiche Branchen von der Automobilindustrie bis zur Medizintechnik. Doch die Entwicklung von zuverlässigen KI-Ansätzen ist nicht trivial. In diese Kapitel werden Lösungsansätze wie Transfer Learning oder Continual Learning präsentiert und anhand von konkreten Beispielen aus verschiedenen Bereichen der Produktion, wie etwa der Massivumformung oder der Laserstrahlbearbeitung dargestellt. Dabei geht es nicht nur darum, isolierte KI-Modelle zu erstellen, sondern auch um die ganzheitliche Integration von KI-Systemen in die Produktion.*

**Speziell dieses Kapitel erhebt aufgrund der Schnellebigkeit dieses Themenfeldes keinen Anspruch auf Vollständigkeit und erläutert vor diesem Hintergrund vielmehr, mit welchen KI-Methoden spezifische Herausforderungen innerhalb der Projekte gelöst wurden. Falls Sie das Themenfeld Generative KI vermissen, empfehlen wir Ihnen die Webseiten der teilnehmenden Hochschulinstitutionen für aktuellere Projekte. Zum Zeitpunkt der Projektausschreibung war dieses Thema noch nicht besonders im Fokus der Öffentlichkeit.*

*Verantwortlich für dieses Kapitel:
Dennis Stoppel, Institut für Fertigungstechnik und Werkzeugmaschinen (IFW)*

KI-METHO

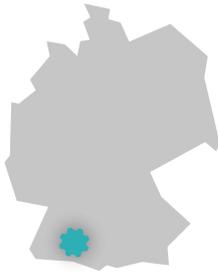


DEN

**NACHDEM SIE DIE HAUS-
AUFGABEN DER DIGITALI-
SIERUNG UND DATEN-
GENERIERUNG ERLEDIGT
HABEN, FINDEN SIE HIER
BEISPIELE ZU KONKRETEN
METHODEN UND
ALGORITHMEN.**



- 
- 146** Selbstlernende Zerspanungssimulation zur Vorhersage der Schnittbelastung für die Einzelstückfertigung mittels Continual Learning
AICoM
- 150** Transfer Learning Ansätze zur serienübergreifenden Qualitätsprognose
IRLeQuM
- 156** Reinforcement Learning gestützter Regelkreis in der Massivumformung
IRLeQuM
- 162** Zeitreihenanalyse durch Faltungnetzwerke bei der Lasermaterialbearbeitung
DIPOOL
- 166** Effizientes Störungsmanagement mit CausalAI
KausaLAssist
- 171** Cyberphysische Lasertechnologie in der Mikrolaserbearbeitung
MEDIUS
- 176** Versatzdetektion an 3D gedruckten Bauteilen durch KI
SenseAI
- 180** Multimodale Prozessüberwachung von pulverbettbasiertem Laserstrahlschmelzen
SenseAI
- 185** Rückverfolgbare Anomalie-Detektion in Lackieranlagen mittels unüberwachtem Transfer Learning
pAInt-Behaviour



SELBSTLERNENDE ZER- SPANUNGSSIMULATION ZUR VORHERSAGE DER SCHNITT- BELASTUNG FÜR DIE EINZEL- STÜCKFERTIGUNG MITTELS CONTINUAL LEARNING

Erkut Sarikaya, Prof. Dr.-Ing. Matthias Weigold (TU Darmstadt, PTW)

Continual-Learning-basierte KI-Modelle verbessern stetig Vorhersagemodelle für die Fertigung individueller Bauteile.

Continual Learning, auch als Lifelong Learning bekannt, ist ein Paradigma des maschinellen Lernens, das darauf abzielt, Modelle zu entwickeln, die sich im Laufe des Lebenszyklus kontinuierlich an neue Daten und Aufgaben anpassen können, ohne dabei bereits erworbenes Wissen zu verlieren. Diese Eigenschaft ist in sich verändernden Umgebungen besonders relevant. Als Beispiel dafür können aus der Zerspanung unterschiedliche Werkstücke sowie Werkzeuge als auch variable Schnittparameter genannt werden. Im Gegensatz zum klassischen maschinellen Lernen ermöglicht das Continual Learning eine fortlaufende Anpassung und Verbesserung des Modells. Das bietet enorme Potenziale für die Zerspanungssimulation beim Fräsen.

Das Fräsen ist einer der komplexesten und flexibelsten Prozesse in der Fertigung mit hohen Toleranzanforderungen. Daher haben für die Zerspanungssimulation maschinelle Lernmethoden mit der zunehmenden Verfügbarkeit maschineninterner Daten durch digitalisierte Werkzeugmaschinen an Bedeutung gewonnen. Sie zeichnen sich besonders dadurch aus, dass sie in der Lage sind, komplexes Verhalten datenbasiert zu

modellieren, ohne explizites Wissen über alle kausalen Zusammenhänge zu haben. Die Leistung von maschinellen Lernmodellen hängt jedoch stark von den bereitgestellten Trainingsdaten ab, die in vielen Fällen, insbesondere in der Einzelstückfertigung, nicht den gesamten Merkmalsraum zukünftiger Aufgaben abdecken. Darüber hinaus ist die Datenverteilung in der Produktionsumgebung häufig nicht stationär, was zu einem Datendrift führt, beispielsweise aufgrund des fortschreitenden Werkzeugverschleißes. In der Praxis bedeutet dies, dass adaptive Modelle benötigt werden, die während der Produktion automatisch nachtrainiert werden können, sobald neue Daten erfasst werden.

Die daraus resultierende Herausforderung besteht darin, neue Informationen aus den erfassten Daten zu generieren, ohne das vorherige Wissen zu verlieren. Doch beim Nachtrainieren eines künstlichen neuronalen Netztes ist bekannt, dass Modellparameter überschrieben werden, was zum so genannten Catastrophic Forgetting führt. Zum Beispiel kann bei der Zerspanungssimulation der werkzeugbezogene Zusammenhang zwischen Eingangsparametern und der Schnittbelastung verloren gehen, wenn das Modell mit neuen Daten von anderen Werkzeugen nachtrainiert wird. Um diesem Problem zu begegnen, sind spezielle Algorithmen und Methoden erforderlich, die sicherstellen, dass das Modell sowohl neues Wissen aufnimmt als auch bestehendes Wissen bewahrt.

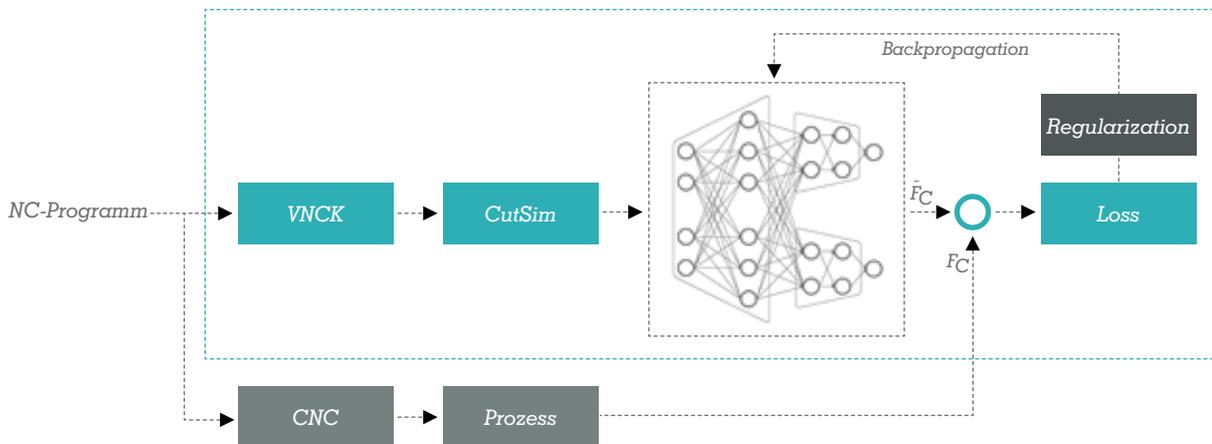


Abbildung 1: Konzept des Continual-Learning-basierten Ansatzes zur selbstlernenden Zerspanungssimulation

Die Methoden des Continual Learnings können allgemein in drei Hauptkategorien unterteilt werden: Regularization, Rehearsal und Dynamic Architecture. Bei Regularization-basierten Methoden wird eine Zusatzfunktion zur Verlustfunktion hinzugefügt, um zu verhindern, dass das Modell alte Informationen vergisst, wenn es neue Daten lernt. Sie zielen darauf ab, das Modell zu stabilisieren, indem sie die Anpassung der Gewichte des neuronalen Netzes regulieren. Diese Methoden stellen sicher, dass wichtige Gewichte für zuvor gelernte Aufgaben weniger verändert werden. Rehearsal-basierte Methoden speichern entweder eine Auswahl alter Daten oder verwenden generative Modelle zur Erzeugung synthetischer Daten, die diese repräsentieren, und mischen diese den neuen Daten hinzu, um das Modell regelmäßig auf beiden Datensätzen zu trainieren. Beim Rehearsal wird dafür gesorgt, dass das Modell kontinuierlich alle bisher gelernten Aufgaben wiederholt und somit das Vergessen minimiert wird. Dynamic-Architecture-basierte Methoden passen die Struktur des neuronalen Netzes an, wenn neue Aufgaben erlernt werden. Dies kann durch das Hinzufügen neuer Knoten oder Schichten zum Netzwerk geschehen, um die Kapazität zu erhöhen. Ziel ist es, das Netzwerk flexibel zu gestalten, um neuen

Anforderungen gerecht zu werden, ohne das gelernte Wissen zu vergessen. Dynamic Architecture ermöglicht es dem Modell, sich an neue und sich verändernde Aufgaben anzupassen, indem es die Netzwerkkapazität dynamisch erweitert.

Für die KI-basierte Zerspanungssimulation zur Vorhersage der Schnittbelastung wird ein hybrider Ansatz, bestehend aus Regularization und Dynamic Architecture, herangezogen. Während Regularization bei der Backpropagation das neuronale Netz vor einer Überanpassung wichtiger Netzparameter bewahrt, ermöglicht Dynamic Architecture durch das Hinzufügen von aufgabenspezifischen Schichten eine kontinuierliche Wissenssteigerung. Abb.1 veranschaulicht das Konzept der umgesetzten Continual-Learning-basierten Zerspanungssimulation für die Vorhersage von Schnittbelastungen.

Für die Bewertung der implementierten Continual-Learning-Methode wurden Validierungsversuche an einer CNC-Werkzeugmaschine durchgeführt. Dabei kamen fünf verschiedene Werkzeugtypen (Task 1: Fräser, Task 2: Bohrer, Task 3: Gewindeschneider, Task 4: Ent-

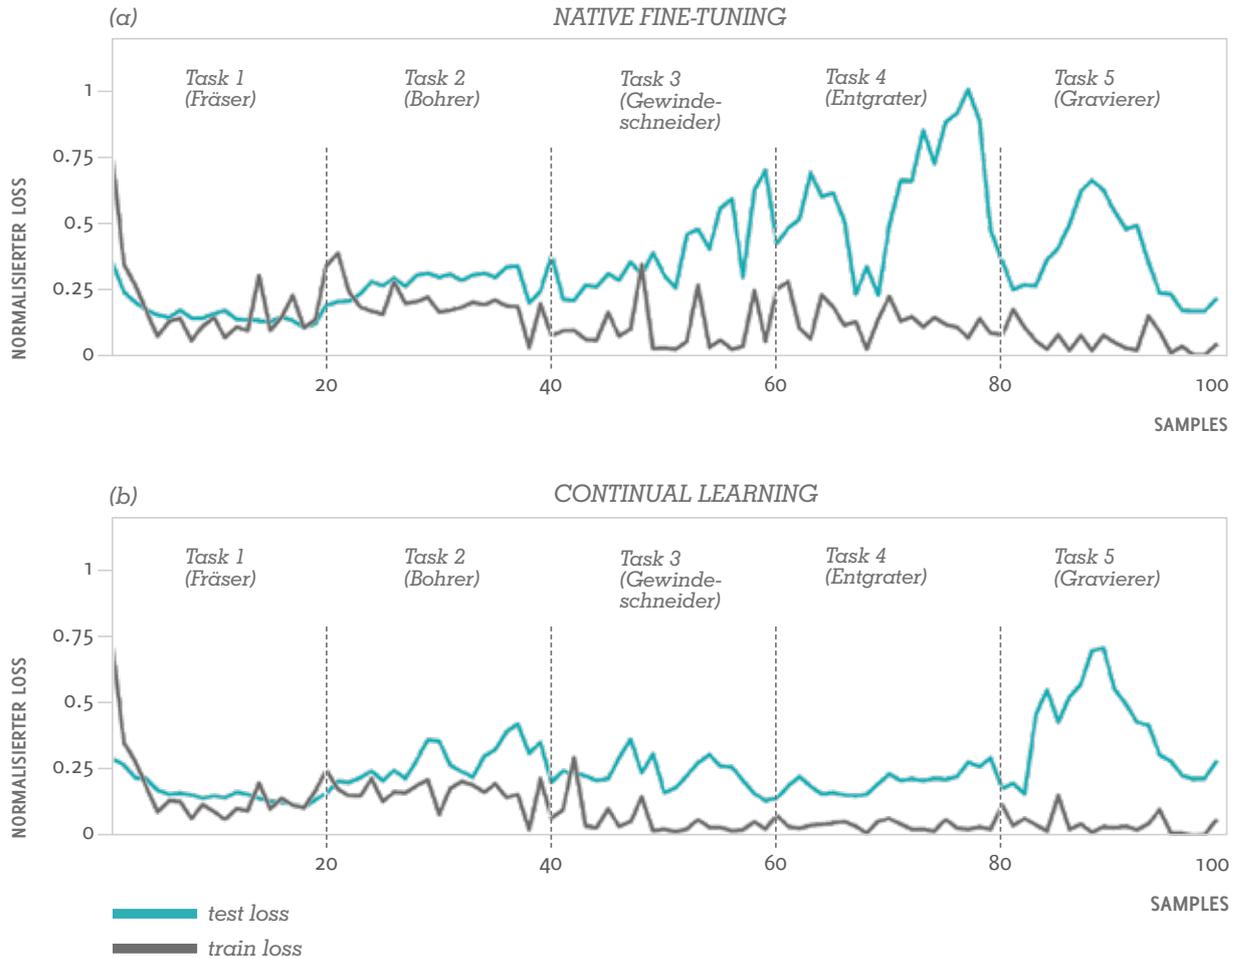


Figure 2: Lernverhalten beim inkrementellen Trainieren mit unterschiedlichen Werkzeugtypen mit (a) Naive Fine-tuning, (b) Continual Learning.

grater und Task 5: Gravierer) zum Einsatz, mit denen jeweils 20 individuelle Bearbeitungsoperationen ausgeführt wurden. Um das kontinuierliche Lernverhalten des KI-Modells zu evaluieren, findet der Trainingsprozess inkrementell statt. Dieser beginnt mit den ersten 20 Datensets der Fräsoperationen (Task 1) und endet mit den 20 Datensets der Gravieroperationen (Task 5). Nach jedem 20. Datenset wird das KI-Modell mit den neuen Werkzeugen weiter trainiert, während die Modellperformance kontinuierlich anhand der Testdaten bewertet wird, die ausschließlich aus den Fräsoperationen (Task 1) bestehen. Diese Evaluierungsmetrik, bekannt als Backward Transfer, misst den Einfluss des Erlernens einer neuen Aufgabe auf die Leistung bei vorherigen Aufgaben.

Abb. 2 zeigt die Lernkurven der Trainings- und Testdaten für die Methoden Naives Fine-Tuning (Abb. 2a) und Continual Learning (Abb. 2b). Es ist deutlich zu erkennen, dass die Lernkurven durch den Continual Learning-Ansatz erheblich verbessert werden. Das Modell in Abb. 2b zeigt bis Task 4 eine nahezu konstante Performance. Erst nach dem Nachtrainieren mit Daten aus den Gravierzyklen verliert das Modell seine Fähigkeit, die Schnittbelastung bei Fräsoperationen (Task 1) vorherzusagen. Dies kann dadurch erklärt werden, dass beim Gravieren kaum Material abgetragen wird und die dabei ausgeübte Schnittbelastung im Vergleich zum Grundrauschen des Signals sehr gering ist. Dadurch verlernt das Modell den kausalen Zusammenhang zwischen den Werkzeug-Werkstück-Eingriffsbedingungen und den entstehenden Schnittbelastungen.



Während das Nachtrainieren des KI-Modells durch die Integration in die CAX-Prozesskette vollautomatisiert im Backend abläuft, zeigt Abb. 3, wie die Simulationsergebnisse eines ausgewählten NC-Programms dem Anwender veranschaulicht werden. Durch farbliche Markierungen der Schnittlasten am Bauteil wird ersichtlich, an welchen Stellen die Prozesslast vordefinierte Schwellwerte überschreitet. Zusammenfassend lässt sich sagen, dass Continual-Learning-basierte Methoden eine vielversprechende Lösung für die Herausforderungen der Zerspanungs-

simulation darstellen. Durch die Fähigkeit, sich kontinuierlich an neue Daten und Aufgaben anzupassen, ohne dabei bereits erworbenes Wissen zu verlieren, bieten sie erhebliche Vorteile gegenüber traditionellen maschinellen Lernansätzen. Die Evaluierung an verschiedenen Werkzeugtypen zeigt deutlich, dass dieser Ansatz die Modellperformance stabilisiert und verbessert. Zukünftig könnten solche selbstlernenden Systeme die Effizienz und Präzision in der Fertigung weiter steigern und somit einen wichtigen Beitrag zur digitalen Transformation der Produktion leisten.

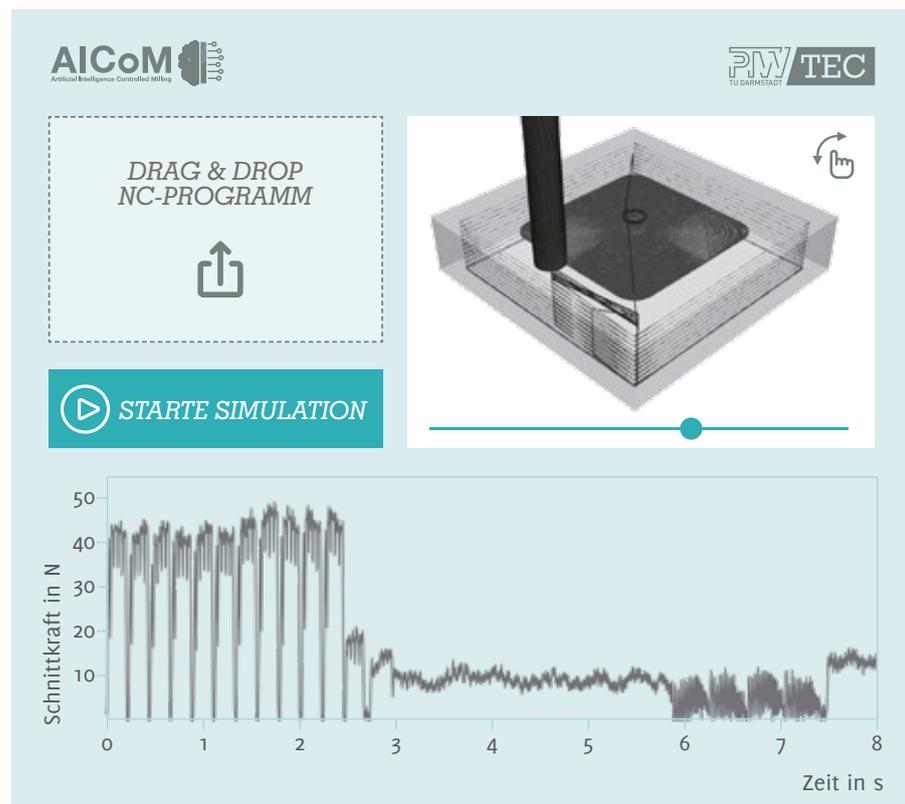
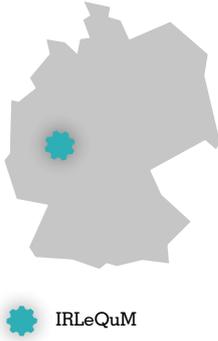


Figure 3: Grafische Benutzeroberfläche der selbstlernenden Zerspanungssimulation



TRANSFER-LEARNING- ANSÄTZE ZUR SERIEN- ÜBERGREIFENDEN QUALITÄTSPROGNOSE

Nils Klasen (Werkzeugmaschinenlabor WZL der RWTH Aachen)

Durch Anwendung von Transfer-Learning-Methoden lassen sich physische Prüfaufwände serienübergreifend reduzieren und durch virtuelle Qualitätsprognosen ersetzen.

In der modernen, variantenvielfältigen Fertigung ist die Gewährleistung gleichbleibend hoher Qualität eine der größten Herausforderungen. Häufig sind umfangreiche physische Prüfaufwände notwendig, um die Qualitätsstandards zu sichern. Um diese Prüfaufwände zu reduzieren, kommen Qualitätsprognosemodelle aus dem Bereich des Machine Learnings (ML) zum Einsatz, die händische Prüfungen durch virtuelle ersetzen. Zum Anlernen dieser Modelle bedarf es einer großen Menge an physischen Prüfdaten, die den Algorithmus dazu befähigen, Wirkzusammenhänge zwischen Prozessinformationen und den Qualitätsmerkmalen des Produktes aufzudecken. Die Modelle werden klassischerweise serienbezogen trainiert, was bedeutet, dass für jede neue Serie eine erhebliche Menge an physisch erhobenen Trainingsdaten erforderlich ist, bevor das Modell in die Nutzungsphase übergeht. Transfer Learning (TL) stellt im Hinblick auf die Reduktion benötigter Prüfaufwände eine vielversprechende Lösung dar. TL ermöglicht die Wiederverwendung vortrainierter Modelle für neue, aber verwandte Aufgaben und revolutioniert damit das Training und die Anwendung von serienübergreifenden Qualitätsprog-

nosemodellen. Durch TL kann der Bedarf an physisch erhobenen Qualitätsdaten für das Modelltraining erheblich reduziert werden, was die Prüfaufwände verringert und wertvolle Ressourcen im Unternehmen spart. Im folgenden Beitrag wird gezeigt, wie TL bei der Erstellung von Qualitätsvorhersagemodellen im Produktionskontext angewendet wird und TL somit die Kosten für manuelle Inspektionen serienübergreifend senkt. Hierzu wird im Vorhinein eine kurze Einführung in die Funktionsweise von Qualitätsprognosemodellen im Allgemeinen gegeben sowie ein Framework zur strukturierten Erhebung der benötigten Produktionsdaten vorgestellt. Das Vorgehen wird im Anschluss anhand eines Praxisbeispiels verdeutlicht.

Wie funktionieren Machine Learning gestützte Qualitätsprognosen?

Traditionell erfolgt die Qualitätssicherung in vielen industriellen Unternehmen anhand von physischen Inspektionen basierend auf Stichproben. Aufgrund der steigenden Verfügbarkeit von Daten aus den Produktionsprozessen und der sich parallel weiterentwickelnden Verfügbarkeit an ML Modellen hat sich an dieser Stelle ein Paradigmenwechsel eingestellt. Immer häufiger setzen Unternehmen auf die Unterstützung neuester Technologien und Methoden, um händische Prüfaufwände zu reduzieren und gleichzeitig die Qualität der eigenen Produkte sicherzustellen. Eine

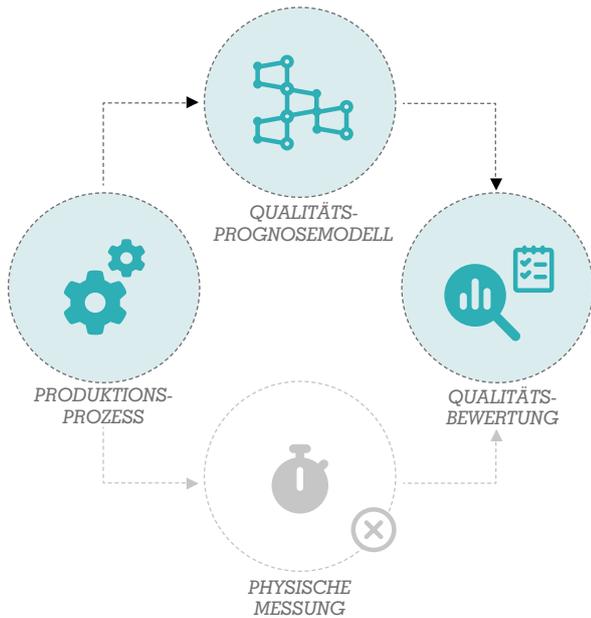


Abbildung 1: Qualitätsprognose im Vergleich zur physischen Messung

Möglichkeit ist hierbei das Nutzen von ML-gestützten Qualitätsprognosemodellen (Abbildung 1).

Datenerfassung und -aufbereitung

Der erste Schritt in der Entwicklung eines ML-gestützten Qualitätsprognosemodells ist die Datenerfassung. Im Produktionsumfeld sammeln Sensoren kontinuierlich Daten über verschiedene Prozessparameter wie Temperatur, Druck, Durchflussrate und Maschinenvibrationen. Diese Prozessdaten werden zusammen mit Qualitätsdaten der Produkte, wie z. B. Abmessungen, Oberflächenbeschaffenheit oder Funktionsfähigkeit, in einer Datenbank gespeichert.

Bevor die Daten für das Training eines ML-Modells verwendet werden können, müssen sie aufbereitet werden. Dies umfasst die Bereinigung von fehlerhaften oder fehlenden Werten, die Normalisierung der Daten und die Auswahl relevanter Merkmale. Der Schritt ist entscheidend, da die Qualität der Daten einen direkten Einfluss auf die Genauigkeit des Modells hat.

Modelltraining

Nachdem die Daten aufbereitet sind, wird das Modell trainiert. Das ML-Modell, beispielsweise ein Multilayer Perceptron (MLP), wird darauf trainiert, Muster in den Prozessdaten zu erkennen, die mit den Qualitätsmerkmalen der Produkte korrelieren. Dabei werden Algorithmen eingesetzt, die die Beziehungen zwi-

schen den Eingabedaten (Prozessparametern) und den Ausgabedaten (Qualitätsmerkmalen) lernen. Eine wichtige Rolle im Trainingsprozess spielt die Lernrate. Die Lernrate bestimmt, wie stark die Gewichte des Modells bei jedem Schritt des Trainings angepasst werden. Eine zu hohe Lernrate kann dazu führen, dass das Modell große Sprünge macht und möglicherweise nicht konvergiert, während eine zu niedrige Lernrate den Trainingsprozess stark verlangsamt und das Modell in lokalen Minima der Optimierungsfunktion stecken bleiben kann.

In der Praxis kann dieser Trainingsprozess iterativ erfolgen, wobei verschiedene Modellarchitekturen und Hyperparameter getestet werden, um die beste Leistung zu erzielen. Das Ziel ist es, ein Modell zu entwickeln, das genaue Vorhersagen über die Qualität gefertigter Produkte treffen kann. Bei der Prognose numerischer Qualitätsmerkmale, wie beispielsweise geometrischer Eigenschaften, wird die Modellgüte anhand der Abweichung zum Realwert anhand einer Verlustfunktion (engl.: Loss Function) bewertet, die es zu reduzieren gilt.

Modellanwendung

Nach erfolgreichem Training wird das Modell in die Produktionslinie integriert. In Echtzeit verarbeitet es die von den Sensoren gesammelten Prozessdaten und gibt Vorhersagen über die Produktqualität ab. Wenn das Modell beispielsweise eine Abweichung von den Qualitätsstandards erkennt, kann es Warnungen ausgeben oder sogar automatische Korrekturmaßnahmen einleiten (KI-Regler), wie etwa das Anpassen von Maschinenparametern oder das Aussortieren fehlerhafter Produkte.

Das IRLeQuM-IT-Infrastruktur-Framework als Leitfaden für die Industrie

Viele Unternehmen aus der produzierenden Industrie sehen vor dem Einsatz von ML-gestützten Prognosemodellen nach wie vor eine große Hürde. Speziell der

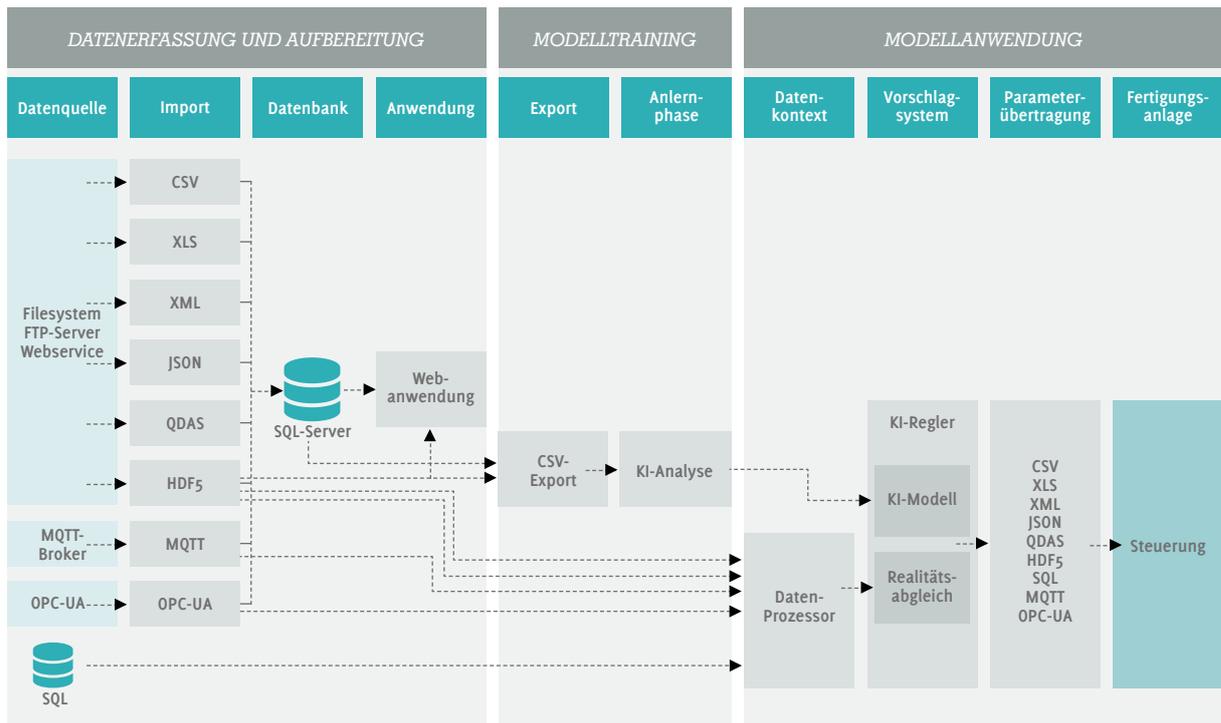


Abbildung 2: IT-Infrastruktur-Framework als Leitfaden für kleine und mittlere Unternehmen

KI-LÖSUNGEN AUS DER PRAXIS / KI-METHODEN

Implementierungsaufwand und die damit verbundene Ressourcenbindung stellen eine Herausforderung dar. Um an dieser Stelle Abhilfe zu schaffen, wurde im Rahmen des Forschungsprojektes IRLeQuM ein universelles IT-Infrastruktur-Framework als Leitfaden für kleine und mittlere Unternehmen entwickelt (Abbildung 2). Untermauert durch definierte Schnittstellen zwischen den einzelnen Komponenten unter Beibehaltung einer hohen Adaptierbarkeit hinsichtlich der unternehmenseigenen Hardware, dient das Framework als Grundlage für Planung, Integration und Nutzung ML-gestützter Qualitätsregelung.

Das Framework umfasst alle Phasen von der Datenerfassung und -aufbereitung über das Modelltraining bis hin zur Anwendung im Produktionskontext. Zudem werden die aufgenommenen Prozessdaten über eine Webanwendung zugänglich gemacht, was der Überwachung unternehmenseigener Prozess-KPI zugutekommt. Da das Forschungsprojekt IRLeQuM die KI-gestützte Prozessregelung fokussiert, wurde das Qualitätsvorhersagemodell um einen Reinforcement-Learning(RL)-Ansatz zu einem KI-Regler erweitert. Weiterführende Informationen über die Integrati-

on und Funktionsweise des RL-Ansatzes finden Sie im Artikel „Reinforcement-Learning-gestützte Qualitätsregelkreise in der Massivumformung“ dieses Projektatlases. Stets liegt der Fokus auf der Prognose der Qualität zur Einsparung physischer Prüfaufwände.

Wie funktioniert Transfer Learning und worin liegt das Potenzial?

Im vorliegenden Kapitel sind wir auf die grundlegende Funktionsweise von ML-gestützten Qualitätsprognosemodellen eingegangen. Aus theoretischer Sicht lassen sich diese in jegliche Produktionsprozesse integrieren, in denen eine ausreichende Anzahl an Prozessinformationen mit hoher Datenqualität zur Verfügung steht, die korrespondierenden Qualitätsmerkmalen zuordenbar ist.

In der industriellen Anwendung stellt die Integration von ML-gestützten Qualitätsprognosemodellen insbesondere bei häufig wechselnden Serien aufgrund hoher Produktvielfalt eine besondere Herausforderung dar. Unterschiede in den Maschineneinstellungen oder

variierende Qualitätsmerkmale führen dazu, dass ein Modell, das für eine Serie gut funktioniert, bei einer anderen Serie möglicherweise ungenau ist. In solchen Fällen muss für jede neue Serie ein eigenes Modell von Grund auf neu trainiert werden. Jedes neue Produktionsserie erfordert eine erhebliche Menge an neuen Daten, um ein präzises Vorhersagemodell zu erstellen. Diese Daten müssen zunächst physisch erhoben, um anschließend zur Modellbildung zu Verfügung zu stehen. Dieses Vorgehen mindert die Anwendungseffizienz erheblich.

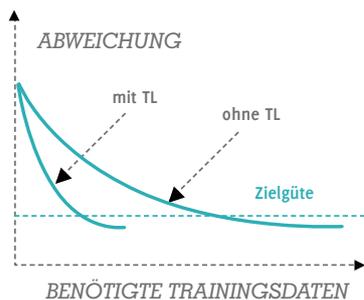


Abbildung 3: Benötigte Trainingsdaten mit und ohne Transfer Learning

An dieser Stelle schaffen Ansätze des TL Abhilfe, indem ein vortrainiertes Modell, das bereits auf einer ähnlichen Aufgabe (Serienproduktion) trainiert wurde, als Ausgangspunkt für ein neues Modell verwendet wird. Das vortrainierte Modell verfügt bereits über grundlegende, prozessspezifische Merkmale und Muster, die aus den Daten der vorherigen Aufgabe gelernt wurden. Diese Merkmale können an die neue Aufgabe angepasst werden, indem das Modell auf den spezifischen Daten der neuen Produktionsserie feinabgestimmt (nachtrainiert) wird. Durch diesen Ansatz wird der Bedarf an großen Mengen physischer Prüfdaten zum Training eines Qualitätsprognosemodells mit entsprechender Zielgüte für jede neue Serie erheblich reduziert (siehe Abbildung 3).

Das Potenzial von TL in der industriellen Anwendung ist enorm. Hier sind einige der wichtigsten Vorteile:

- **Reduzierter Datenaufwand:** Da vortrainierte Modelle verwendet werden, ist der Bedarf an neuen Daten für jede neue Produktionsserie geringer. Dies spart Zeit und Ressourcen bei der Datenerhebung und -verarbeitung.
- **Schnellere Modellentwicklung:** Die Wiederverwendung von bereits trainierten Modellen beschleunigt den Entwicklungsprozess. Neue Modelle können schneller erstellt und in die Produktion integriert werden, was die Gesamteffizienz erhöht.
- **Kostensparnis:** Weniger physische Prüfungen und geringerer Datenaufwand führen zu einer Reduzierung der Kosten für die Qualitätskontrolle. Dies ist besonders vorteilhaft für kleinere Unternehmen mit begrenzten Ressourcen.
- **Höhere Genauigkeit:** Durch die Nutzung von Wissen aus früheren Serien kann die Genauigkeit der Modelle verbessert werden. Vortrainierte Modelle verfügen bereits über ein tiefes Verständnis der grundlegenden Muster und Merkmale des Prozesses, die für die Qualitätsprognose relevant sind.
- **Anpassungsfähigkeit:** TL ermöglicht es, Modelle schnell an neue Bedingungen anzupassen. Dies ist besonders wichtig in dynamischen Produktionsumgebungen, in denen sich die Anforderungen und Bedingungen häufig ändern.

Praxisbeispiel: Transfer Learning zur Reduktion der physischen Prüfaufwände in der Massivumformung

Im Rahmen des Forschungsprojektes IRLeQuM wurde ein TL-Strategie-Benchmark entwickelt, das es produzierenden Unternehmen ermöglicht, verschiedene



Strategien des TL ohne eigene Implementierungsaufwände zu Testen, und die vielversprechendste im Rahmen ihres Anwendungsfalls zu integrieren. Der Benchmark lässt sich nahtlos in die Modelltrainingsphase des zuvor vorgestellten übergeordneten Leitfadens (Abbildung 2) integrieren. Das Transfer-Learning-Framework umfasst fünf verschiedene Strategien, die sich in der Art des übertragenen Wissens und dem Ansatz zur erneuten Modellanpassung unterscheiden:

Strategie 1: Modellstrukturtransfer

In der ersten Strategie wird nur die Modellstruktur des vortrainierten MLP übertragen, während die Gewichte neu initialisiert werden. Das resultierende Modell, auch Kontrollmodell genannt, wird mit ähnlichen Hyperparametern wie das vortrainierte Modell auf den neuen Daten trainiert. Dieses Modell dient als Benchmark, um die Leistung eines von Grund auf neu trainierten Modells mit den nachfolgenden Ansätzen zu vergleichen.

Strategie 2: Gefrorene Schichten

In der zweiten Strategie werden sowohl die Modellstruktur als auch die vortrainierten Gewichte übertragen. Die Gewichte der unteren Schichten bleiben konstant (gefroren), während nur die oberen Schichten mit neuen Daten trainiert werden. Typischerweise werden die Gewichte in den oberen Schichten mit einer niedrigeren Lernrate feinabgestimmt. Diese Strategie zielt darauf ab, das allgemeine Wissen der unteren Schichten beizubehalten und nur die oberen Schichten an die neue Aufgabe anzupassen.

Strategie 3: Soft Start

Der Soft-Start-Ansatz wird als dritte Strategie verwendet, bei der das vortrainierte Netzwerk zusammen mit seinen Gewichten übertragen wird. Anschließend wird das Modell mit einer niedrigeren Lernrate im Vergleich zum vortrainierten Netzwerk auf den neuen Daten trainiert. Die Idee hinter diesem Ansatz ist, dass das Modell während des Trainings auf den vorheri-

gen Daten wahrscheinlich zu einer nahezu optimalen Lösung konvergiert ist und möglicherweise nur eine Feinabstimmung für die neuen Daten benötigt.

Strategie 4: Standard-Fine-Tuning

In der vierten Strategie werden die Gewichte der oberen Schichten neu initialisiert und mit einer höheren Lernrate von Grund auf neu trainiert, während die Gewichte der unteren Schichten mit einer niedrigeren Lernrate feinabgestimmt werden. Diese Strategie ermöglicht es, die allgemeinen Repräsentationen der unteren Schichten an die neuen Daten anzupassen.

Strategie 5: Gefrorenes Start-Fine-Tuning

Die fünfte Strategie ähnelt der vierten, jedoch erfolgt das Training in zwei Phasen. In Phase 1 bleiben die unteren Schichten gefroren, während nur die oberen Schichten trainiert werden. In Phase 2 werden alle Schichten mit einer niedrigeren Lernrate trainiert, um eine gewisse Flexibilität in den unteren Schichten zu ermöglichen und sie an die neuen Daten anzupassen.

Zur Validierung der Strategien im Rahmen des Projekatlasses wurde ein Datensatz über 15 verschiedene Chargen mit jeweils 100 Datenpunkten erstellt. Die Beziehung zwischen den Merkmalen und den Zielwerten basiert auf abstrahierten physikalischen Korrelationen des Kaltwalzprozesses eines Anwendungsunternehmens aus dem IRLeQuM-Forschungskonsortium. Weiterführende Informationen zum Anwendungsfall sind dem Artikel „Reinforcement-Learning-gestützte Qualitätsregelkreise in der Massivumformung“ zu entnehmen. Der Datensatz weist über die Zeit eine Divergenz auf und hat für jede Charge eine unterschiedliche Verteilung. Um zufällige Einflüsse innerhalb der Produktionsprozesse zu simulieren, wurde eine zufällige Streuung hinzugefügt. Im Folgenden wird untersucht, inwiefern die benötigte Datenmenge zum Training eines Qualitätsprognosemodells einzelner Serien durch die Anwendung der vorgestellten Strategien reduziert werden kann. Das fokussierte Qualitätsmerkmal ist die resultierende Bauteildicke. Aufgezeichnete



und zur Verfügung stehende Prozessparameter des Massivumformprozesses umfassen chemische und physikalische Eigenschaften des Eingangsmaterials, Sollwerte, Vorschubgeschwindigkeiten, Zustellungen sowie resultierende Presskräfte, Prozess- und Umgebungstemperaturen u. v. m. Mittels des TL-Benchmarks wird untersucht, inwiefern die benötigte Datenmenge zum Training eines Qualitätsprognosemodells serienübergreifend reduziert werden kann. Strategie 1 definiert als Basismodell die Vergleichsgrundlage für das Benchmarking, und zwar als das Modell, bei dem lediglich die Modellarchitektur, jedoch kein explizites Wissen aus vorherigen Modelltrainings wiederverwendet wird. In Tabelle 1 ist anwendungsfallabhängig dargestellt, inwieweit sich physische Prüfaufwände durch virtuelle Qualitätsinspektionen ersetzen lassen. Eine 100%-Quote in der Kategorie „Notwendige physische Qualitätsinspektionen“ entspräche einer traditionellen, durch einen Qualitätsprüfenden durchgeführten 100%-Prüfung. Jede Prüfung, die basierend auf einer Qualitätsprognose des Vorhersagemodells durchgeführt werden kann, reduziert diesen Anteil. Für die Bewertung der Strategien werden die dazugehörigen Modelle mit steigender Anzahl an Datenpunkten der physischen Qualitätsinspektion trainiert. Ist die Zielgüte erreicht, werden virtuelle Qualitätsinspektionen simuliert und mit den Realwerten verglichen. Dabei wird die Qualitätsprognose als repräsentativ beurteilt, wenn das prognostizierte Qualitätsmerkmal innerhalb anwendungsfallabhängig definierter Abweichungen vom Realwert liegt. Wird die Qualitätsprognose als nicht repräsentativ beurteilt, wird das Modell, basierend auf zusätzlichen Datenpunkten der physischen Qualitätsprüfung, nachtrainiert. Die Tabelle zeigt die Bewertung der verschiedenen Strategien. Aufgrund der geringen Anzahl an produzierten Produkten pro Serie ist der Anteil an vorhandenen Datenpunkten, die für ein serienbezogenes Neutaining (Strategie 1) des Qualitätsprognosemodells benötigt werden, mit 80 % sehr hoch. Im Vergleich zeigen besonders die Anwendung der Strategien 3 und 5 großes Potenzial hinsichtlich eines verfrühten Wechsels

von Modelltrainings in die Modellnutzungsphase. Beispielsweise lassen sich die notwendigen physischen Qualitätsinspektionen zum Erheben der Datengrundlage des Modelltrainings durch die Anwendung der Strategie 5 (Gefrorenes Start-Fine-Tuning) auf 19 % aller 1500 Produkte in den 15 verschiedenen Serien reduzieren, was zu einer signifikanten Einsparung von Prüfressourcen führt.

angewandte TL-Strategie:	1	2	3	4	5
Notwendige physische Qualitätsinspektion	80%	64%	21%	36%	19%
Mögliche virtuelle Qualitätsinspektion	20%	36%	79%	64%	81%

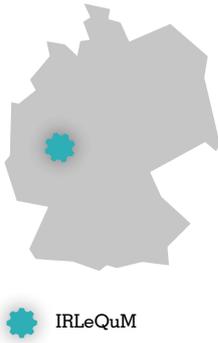
Tabelle 1: Validierungsergebnisse der angewandten TL-Strategien im Anwendungsfall

Zusammenfassung

Im Rahmen des Forschungsprojektes IRLeQuM konnte das Potenzial von Transfer-Learning(TL)-Ansätzen zur serienübergreifenden Reduktion von physischen Prüfaufwänden in Kombination mit der Nutzung von Qualitätsprognosemodellen aufgezeigt werden. Ein Benchmarking zum Aufdecken der anwendungsfallabhängig passenden Strategie ermöglicht eine branchenunabhängige und implementierungsaufwandsarme Anwendbarkeit in der Industrie. Bei der Anwendung des TL-Benchmarkings im Rahmen des vorgestellten IT-Infrastruktur-Frameworks zur Planung, Implementierung und Nutzung von Qualitätsprognosemodellen steht das IRLeQuM-Projektteam gerne zur Verfügung.

Acknowledgements

Diese Forschung wurde vom Bundesministerium für Bildung und Forschung in Deutschland (BMBF) im Rahmen des Verbundforschungsprojekts IRLeQuM (Industrielles Reinforcement-Lernen für die Qualitätskontrolle von Massivumformprozessen) finanziert, Förderkennzeichen O2P20A073.



REINFORCEMENT- LEARNING-GESTÜTZTER REGELKREIS IN DER MASSIVUMFORMUNG

Ronja Witt, Chris Schönekehs (Werkzeugmaschinenlabor WZL der RWTH Aachen)

Durch die Integration von Reinforcement Learning (RL) in Qualitätsregelkreise können die Prozessparameter komplexer Fertigungsprozesse kontinuierlich optimiert werden, was zu verbesserter Produktqualität, reduzierter Ausschussrate und verbesserter Prozessstabilität führt.

Die Massivumformung spielt eine wichtige Rolle in einer Vielzahl von Branchen wie der Automobil-, Bau- oder Medizintechnik ^[1]. Es handelt sich dabei um komplexe Prozesse, auf die mehrere Einflussfaktoren einwirken. Die Einstellung der Prozessparameter für die Massivumformmaschinen basiert häufig auf Expertenwissen und wird während des Prozesses durch Regelkreise angepasst. Standardregelkreise sind nicht in der Lage, externe Faktoren wie Materialwechsel, Werkzeugverschleiß oder unbekannt

ge zwischen Qualität und Prozesseinstellungen zu berücksichtigen ^[2]. Reinforcement-Learning(RL)-basierte Regler bieten einen vielversprechenden Ansatz, um die skizzierten Herausforderungen in Bezug auf Material- und Umwelteinflüsse zu bewältigen. RL-Methoden können zur Entwicklung komplexer Steuerungssysteme eingesetzt werden, um konventionelle Steuerungssysteme durch ihre Anpassungsfähigkeit an sich ändernde Bedingungen und externe Einflüsse zu erweitern. Diese Eigenschaft kann zu einer geringeren Ausschussrate, einer höheren Produktivität und einer größeren Prozessstabilität beitragen ^[3].

In diesem Beitrag wird ein verallgemeinertes Qualitätsregelkreis(QRK)-Framework, basierend auf Reinforcement Learning (RL), beschrieben, das auf einen Massivumformprozess angewendet wird, um die Char

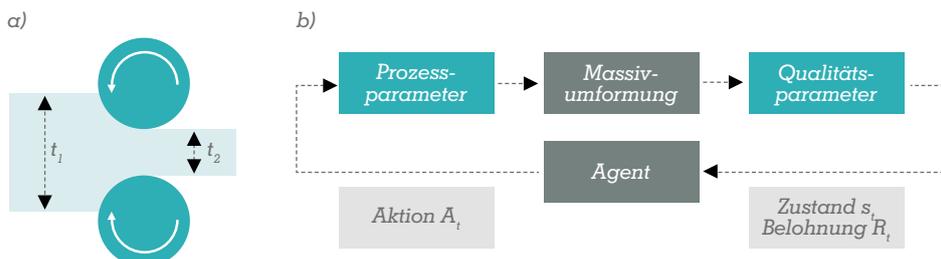


Abbildung 1: a) Kaltwalzprozess [4];
b) Markov Decision Process [5]



Einführung in Reinforcement Learning und Definition des Anwendungsfalls

In diesem Abschnitt wird zunächst die Funktionsweise von RL-Learning näher erläutert. Daraufhin wird der Kaltwalzprozess als Anwendungsfall vorgestellt, auf den das entwickelte RL-Framework angewendet wird.

RL ist ein Ansatz des maschinellen Lernens, bei dem ein Agent durch Interaktion mit einer Umgebung lernt, optimale Entscheidungen zu treffen, um langfristig eine bestimmte Zielsetzung zu erreichen. Der vorliegende Kaltwalzprozess wird als Markov Decision Process (MDP) klassifiziert. Ein MDP ist eine diskrete Darstellung des Problems der stochastischen optimalen Regelung und besteht aus diskreten Zuständen s_t , Aktionen A_t und Belohnungen R_t (vgl. Abbildung 1). Die Interaktion eines RL-Agenten mit seiner Umgebung folgt einem iterativen Prozess. Der Agent beeinflusst den Zustand s_t des Systems durch Aktionen A_t und erhält daraufhin eine Belohnung R_t . Der Agent lernt aus der Interaktion mit dem System, welche Aktionen A_t bei welchen Systemzuständen die Belohnung R_t maximieren. Durch die Einbeziehung zukünftiger Belohnungen kann der Agent eine langfristige Strategie zur Optimierung der Gesamtleistung entwickeln^[5, 6].

Beim Kaltwalzen wird der Spalt zwischen zwei Walzen so eingestellt, dass unterschiedliche Materialdicken erreicht werden, wie in Abbildung 1 a) dargestellt^[4]. Die Implementierung einer Regelung, die in der Lage ist, alle Prozessparameter und die Auswirkungen von unterschiedlichen Paramtereinstellungen beim Kaltwalzen zu berücksichtigen, stellt eine Herausforderung dar. Die Wechselwirkungen und Auswirkungen von unterschiedlichen Parameterkombinationen an der Anlage und deren Einfluss auf Materialdicke und Materialeigenschaften können nur schwer modelliert werden. Zusätzlich treten durch externe Einflussfaktoren Effekte auf, die durch herkömmliche Regler nicht

geregelt werden können^[5]. In diesem Zusammenhang wird RL eingesetzt, um den Walzspalt in Abhängigkeit von der zu erzielenden Materialdicke unter Berücksichtigung äußerer Einflüsse kontinuierlich zu regeln und zu optimieren. Im Kaltwalzprozess bestimmt der RL-Agent die beste Parameterkonfiguration, um die Qualität des Endprodukts zu verbessern und die gewünschte Materialdicke zu erreichen. Der Agent wird trainiert, indem er Belohnungen, basierend auf der Abweichung des Qualitätsparameters t_2 vom Sollzustand, erhält.

Einführung des-Reinforcement-Learning Frameworks

In diesem Abschnitt wird ein umfassendes RL-Framework zur Steuerung von Massivumformprozessen präsentiert, welches das Benchmarking von Algorithmen ermöglicht. Es werden sechs Algorithmen ausgewählt und miteinander verglichen.

Framework für den RL-Qualitätsregelkreis

Das Framework^[8] besteht aus drei Hauptkomponenten: RL-Algorithmen, Hyperparameteroptimierung (HPO) und die virtuelle Trainingsumgebung, die im Folgenden näher erläutert werden (siehe Abbildung 2).

Für das Framework werden sechs vielversprechende RL-Algorithmen (DDPG1, TD32, SAC3, A2C4, TRPO5, PPO6) eingesetzt^[5].

Während des Trainings werden die Hyperparameter der RL-Algorithmen mithilfe der Python-Bibliothek Optuna^[7] optimiert, um eine optimale Parameterkonfiguration für den jeweiligen Anwendungsfall zu gewährleisten.

Um die virtuelle Trainingsumgebung für den RL-Regler zu erstellen, kann entweder eine Prozesssimulation oder ein aus historischen Daten erstelltes Regressionsmodell verwendet werden. Die Entwicklung einer

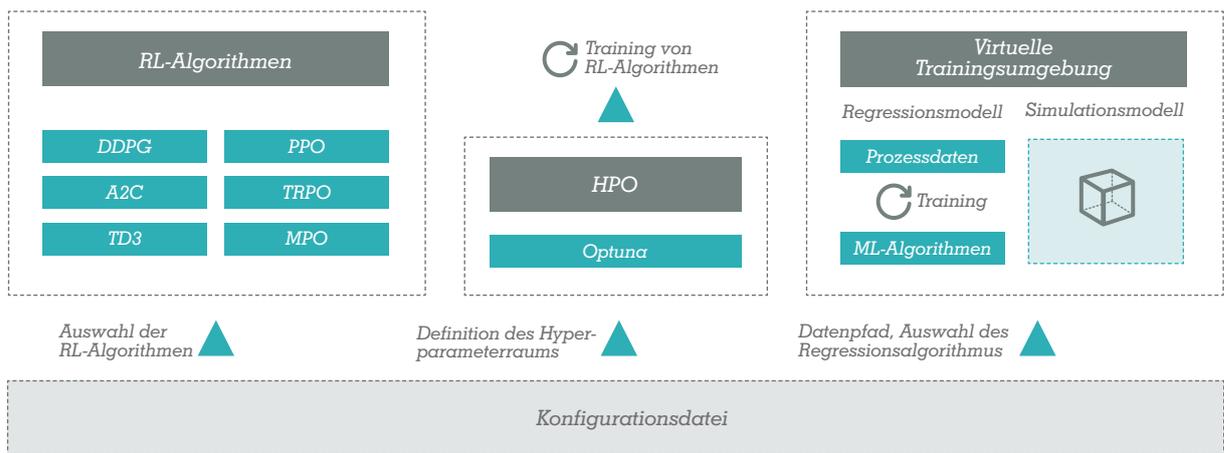


Abbildung 2: Struktur des Reinforcement Learning

Prozesssimulation ist oft zeitaufwendig und verbunden mit hohem Ressourcenaufwand. Die Erstellung eines Regressionsmodells auf Basis historischer Daten ist dagegen weniger aufwendig, sofern eine Datenbasis in ausreichender Qualität und Quantität vorhanden ist.

Framework ^[8] Das Framework ist so konzipiert, dass es verallgemeinerbar ist. Die Anpassung an spezifische Anwendungsfälle beschränkt sich auf die Konfigurationsdatei, in der wesentliche Informationen und die für das Training notwendigen Datensatzanforderungen gespeichert sind. Die Algorithmenauswahl, HPO und der Aufbau der virtuellen Trainingsumgebung wurden so konzipiert, dass hier keine Anpassungen für andere Anwendungsfälle vorgenommen werden müssen ^[8].

Leitfaden zur Nutzung des Frameworks für Unternehmen

Ein Leitfaden zur Nutzung des im vorherigen Abschnitt vorgestellten Frameworks auf unterschiedliche Anwendungsfälle in der Industrie ist in Abbildung 3 dargestellt. Das Vorgehen gliedert sich in sechs Phasen.

Problemidentifikation: Zunächst werden die spezifischen Herausforderungen des Prozesses bestimmt.

Datenbeschaffung: Danach folgt eine automatisierte Extraktion von Prozessdaten. Es existieren drei wesentliche Kategorien von relevanten Daten:

1. Prozessparameter und Umweltfaktoren, die einen

signifikanten Einfluss auf die zu regelnden Qualitätsparameter ausüben

2. Regelparameter, die vom Agenten angepasst werden, um den Prozess zu regeln
3. Qualitätsmerkmale, die die erzielte Produktqualität beschreiben

Datenaufbereitung: Die Datenaufbereitung umfasst das Bereinigen und Transformieren von Rohdaten, um sie in eine Form zu bringen, die von Machine-Learning-Algorithmen verarbeitet werden kann.

Trainingsumgebung: Erstellung einer Simulationsumgebung oder eines Regressionsmodells

RL-Agenten: Das Framework stellt mehrere RL-Algorithmen für das Training zur Verfügung. Die Hyperparameter der Algorithmen werden optimiert und die beste Kombination ausgewählt. Die verschiedenen Algorithmen werden eingesetzt und miteinander verglichen. Hieraus wird ein geeigneter Algorithmus für den vorliegenden Anwendungsfall ausgewählt.

RL-Agent einsetzen: Der trainierte Agent wird in die



Abbildung 3: Leitfaden für die Nutzung des Frameworks [8]

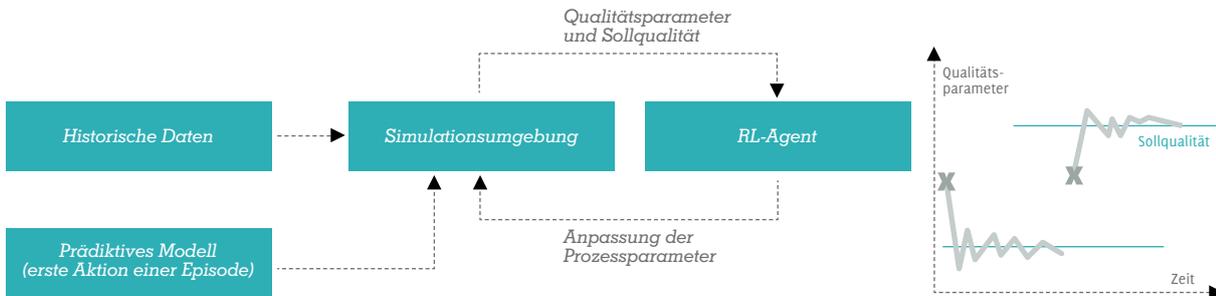


Abbildung 4: Formulierung des Problems als MDP [8]

reale Umgebung eingesetzt. Es ist abzuwägen, ob der Agent direkt in den Prozess eingreifen oder vorerst eine weisende Rolle einnehmen soll. Hierbei schließt der Mensch den QRK.

Mithilfe dieses aus sechs Punkten bestehenden Leitfadens lässt sich das Framework auf verschiedene Prozesse übertragen und effizient nutzen. Die Schritte der Problemidentifikation, Datenbeschaffung und Datenaufbereitung sind hierbei spezifisch und müssen für jeden Anwendungsfall separat durchlaufen werden. Hingegen sind die Erstellung des Trainings-Environments sowie die Ermittlung und der Einsatz des RL-Agenten Teil des generalisierten Frameworks. [8]

Benchmarking der ausgewählten Ansätze

In diesem Abschnitt wird zunächst das reale System des Massivumformprozesses als MDP formuliert. Daraufhin werden der experimentelle Aufbau, die verwendeten Metriken für die Evaluation sowie die HPO des Benchmarkings beschrieben. Abschließend werden die Ergebnisse des Benchmarkings der RL-Algorithmen vorgestellt.

Formulierung des realen Systems als MDP

Abbildung 4: Formulierung des Problems als MDP [8]

Die Formulierung des realen Problems als MDP hat eine große Auswirkung auf den erfolgreichen Einsatz von RL-Algorithmen. Im Folgenden wird ein mögli-

cher Ansatz der Formulierung beschrieben, der sich besonders für das vorliegende System eignet (siehe Abbildung 4).

Der gewählte Ansatz besteht aus einem RL-Regler, der mit einer auf historischen Daten basierenden Simulationsumgebung interagiert. Ein Schritt in der Simulationsumgebung entspricht einem gefertigten Bauteil. Der RL-Agent erhält nach jedem Prozessschritt die gefertigte Materialdicke t_2 als Zustand. Die Belohnung des RL-Agenten basiert auf dem Unterschied der gefertigten Materialdicke zur Soll-Materialdicke. Daraufhin nimmt der RL-Agent als Aktion Anpassungen an den Prozessparametern vor. Eine Episode umfasst 50 Prozessschritte, in denen der Agent seine kumulative Belohnung versucht zu maximieren. Zu Beginn jeder Episode werden die Prozessbedingungen randomisiert und ein prädiktives Modell liefert anfängliche Prozessparameter, die der Agent weiter anpasst.

Der Ansatz strebt an, eine Strategie zu entwickeln, um die besten Einstellparameter in möglichst wenigen Schritten zu erreichen. Indem sich die Entscheidungsgrundlage des Reglers auf die unmittelbaren Qualitätsparameter beschränkt, wird die Komplexität des Entscheidungsprozesses stark reduziert. Die Reduzierung der Komplexität erhöht die Anpassungsfähigkeit des Systems, da die Abhängigkeit von externen Variablen, die nicht in den historischen Daten enthalten sind, minimiert wird. Dies führt zu einer größeren



Robustheit gegenüber Änderungen in der Umwelt oder der Systemdynamik.

Experimenteller Aufbau: Für das Benchmarking der Algorithmen werden zunächst die vielversprechendsten Algorithmen ausgewählt, um daraufhin eine HPO für die ausgewählten Algorithmen durchzuführen. Während des Trainings und der Evaluierung der RL-Agenten werden die Prozessparameter mit jeder neuen Episode angepasst.

Leistungsmetriken: Für die Bewertung der RL-Algorithmen wird der durchschnittliche undiskontierte Ertrag (engl.: Average Undiscounted Return, AUR) als primäre Leistungsmetrik herangezogen. Der AUR quantifiziert die durchschnittliche kumulative Belohnung, die ein Algorithmus über eine Reihe von Episoden erzielt. Um die Zuverlässigkeit der Bewertungen zu erhöhen, werden neben dem AUR auch Konfidenzintervalle einbezogen.

Optimierung der Hyperparameter: Während der HPO wurden für jeden Algorithmus zehn Iterationen mit einer Lernrate im Bereich von 0,0005 bis 0,00005 und einem konstanten Diskontierungsfaktor von 0,1 durchgeführt.

Ergebnisse des Benchmarkings

Die vielversprechendsten RL-Algorithmen wurden zunächst ausgewählt, um die HPO effizienter zu gestalten. Dieser Auswahlprozess umfasste ein Benchmarking, wobei alle sechs im RL-Framework enthaltenen Algorithmen mit einer Lernrate von 0,0001 trainiert wurden.

Tabelle 1 zeigt die durchschnittlichen Belohnungen und Konfidenzintervalle der trainierten RL-Algorithmen. Die Algorithmen PPO, DDPG und TD3 hatten höhere durchschnittliche Belohnungen und engere Konfidenzintervalle als die anderen und wurden daher für die weitere Analyse und HPO ausgewählt. Basierend auf den drei ausgewählten Algorithmen und

Algorithm	Learning Rate	Average Rewards	Lower Bounds	Upper Bounds	avg steps to target
TD3	0.000377	-1.08814	-1.42805	-0.74823	1.39
DDPG	0.000441	-1.16729	-1.50719	-0.82739	1.38
TD3	0.000084	-1.22817	-1.58639	-0.86996	1.43
DDPG	0.000341	-1.23036	-1.59250	-0.86822	1.42
TD3	0.000171	-1.38770	-1.77578	-0.99961	1.68
DDPG	0.000429	-1.41630	-1.80821	-1.02439	1.68
DDPG	0.000209	-1.46709	-1.88524	-1.04895	1.68
DDPG	0.000095	-1.52283	-1.98119	-1.06448	1.65
TD3	0.000358	-1.53985	-2.00237	-1.07732	1.64
DDPG	0.000066	-1.54342	-1.92246	-1.16437	1.85

Tabelle 1: Benchmarkingergebnisse von verschiedenen Algorithmen [8]

10 Iterationen der HPO wurden insgesamt 30 RL-Agenten trainiert. Die Leistung der 10 besten RL-Agenten ist in Tabelle 2 dargestellt. Die Bewertung basiert auf den durchschnittlichen Belohnungen, den Konfidenzintervallen und der durchschnittlichen Anzahl der Schritte zur Zielerreichung. Die durchschnittlichen Belohnungen liegen zwischen -1,08814 und -1,54342. Die Algorithmen TD3 und DDPG zeigen eine vergleichbare Leistung, wobei DDPG eine etwas geringere durchschnittliche Belohnung aufweist. Die durchschnittlichen Schritte bis zum Ziel liegen zwischen 1,38 und 1,85.

Die erzielten Ergebnisse zeigen, dass der TD3-Algorithmus mit einer Lernrate von 0,00043 und einem Diskontierungsfaktor von 0,1 die höchste durchschnittliche Belohnung und die geringste Anzahl an Schritten bis zur Erreichung des gewünschten Qualitätsniveaus aufweist.

Algorithm	Average Rewards	Lower Bounds	Upper Bounds
PPO	-2.123	-2.546	-1.700
DDPG	-1.684	-2.108	-1.260
TD3	-1.534	-1.910	-1.158
TRPO	-4.968	-5.418	-4.518
A2C	-9.260	-9.657	-8.863
SAC	-3.592	-4.042	-3.143

Tabelle 2: Benchmarkingergebnisse der zehn besten Agenten [8]



Zusammenfassung und Ausblick

Durch die Integration von RL in Qualitätsregelkreise können die Prozessparameter kontinuierlich optimiert werden, was zu verbesserter Produktqualität, reduzierter Ausschussrate und verbesserter Prozessstabilität führt. Das Framework umfasst sechs der für das vorliegende Problem vielversprechendsten RL-Algorithmen, die während der Literaturrecherche identifiziert wurden. Die Ergebnisse ergaben, dass die Algorithmen PPO, DDPG und TD3, was die durchschnittliche Belohnung und Effizienz bei der Erreichung der Zielqualitätsparameter angeht, die anderen Algorithmen konsequent übertrafen. HPO verfeinerte die Leistung dieser Algorithmen weiter. Die erzielten Ergebnisse zeigen, dass der TD3-Algorithmus mit einer Lernrate von 0,00043 und einem Diskontierungsfaktor von 0,1 die höchste durchschnittliche Belohnung und die geringste Menge an Schritten bis zur Erreichung der gewünschten Qualität aufweist. Durch die Generalisierung des Frameworks besteht die Möglichkeit, es auch für andere Anwendungsfälle in der Produktionstechnik gemäß dem Nutzungsleitfaden anzuwenden.

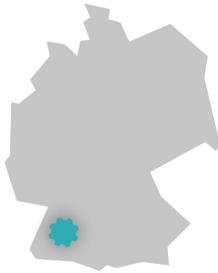
Acknowledgements

Diese Forschung wurde vom Bundesministerium für Bildung und Forschung in Deutschland (BMBF) im Rahmen des Verbundforschungsprojekts IRLeQuM (Industrielles Reinforcement-Lernen für die Qualitätskontrolle von Massivumformprozessen) finanziert,

Förderkennzeichen O2P20A073.

Literatur

- [1] Schuler GmbH. Handbuch der Umformtechnik. Berlin, Heidelberg: Springer Berlin Heidelberg; 1996.
- [2] Polyblank JA, Allwood JM, Duncan SR. Closed-loop control of product properties in metal forming: A review and prospectus. In: Journal of Materials Processing Technology 2014;214:11. p. 2333-2348.
- [3] Käufer H, Lemke H-J. Überwachung und Regelung von Spritzgießmaschinen durch Einbeziehung von Produkteigenschaften. In: Syrbe M, Thoma M, editors. Fachberichte Messen, Steuern, Regeln. Berlin; 1983. p. 210-220.
- [4] Lange K, Kurz N. Grundlagen für das Kaltwalzen von Voll- und Hohlkörpern nach dem Grob-Verfahren. Berlin, Heidelberg: Springer Berlin Heidelberg; 1987.
- [5] Sutton RS, Barto AG. Reinforcement Learning. 2nd ed. Cambridge: MIT Press; 2018.
- [6] Bellman R. A Markovian Decision Process. In: Journal of Mathematics and Mechanics 1957;6:5. p. 679-684.
- [7] Akiba T, Sano S, Yanase T, Ohta T, Koyama M. Optuna: A Next-generation Hyperparameter Optimization Framework. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA; 2019. p. 2623-2631.
- [8] Schönekehs CR, Witt R, Schmitt RH. Ein flexibles Framework für Reinforcement Learning. Zeitschrift für wirtschaftlichen Fabrikbetrieb 2023;118:11. p. 795-800.



ZEITREIHENANALYSE DURCH FALTUNGSNETZWERKE BEI DER LASERMATERIAL- BEARBEITUNG

Johannes Steffens, Michael Heizmann (Karlsruhe Institut für Technologie, Institut für Industrielle Informationstechnik)

Bei der Lasermaterialbearbeitung kann mit Hilfe von Faltungsnetzwerken der Abbruch des stabilen Prozessablaufs in weniger als einer Millisekunde detektiert werden.

Das Hochgeschwindigkeits-Laserstrahlschneiden bietet die Möglichkeit, präzise Produkte mit hoher Geschwindigkeit und maximaler Flexibilität herzustellen. Ziel des Verbundprojektes „DIPOOL“ ist es, die Produktivität des Laserschneidens zu maximieren indem Verfahrensgrenzen besser ausgenutzt werden, Ausschuss reduziert und die Betriebsbereitschaft der Anlagen erhöht wird. Dies soll durch eine Prozessüberwachung ermöglicht werden, die eine dynamische Reaktion auf Störgrößen erlaubt. Eine Herausforderung besteht darin, dass der Prozess bei Geschwindigkeiten nahe der Maximalgeschwindigkeit nur geringe Reserven bezüglich unvermeidbarer Parameterschwankungen aufweist. Dies kann zu Prozessabbrüchen oder reduzierter Schnittqualität führen. Darüber hinaus gibt es zum Teil unvorhersehbare Fehlerquellen, die bei hohen Geschwindigkeiten zum Abbruch des Schnittes führen können. In Abbildung 1.1 kann ein solcher Schnittabbruch gesehen werden. Neben der Unbrauchbarkeit des Werkstücks besteht die Gefahr, dass Teile des Laserschneidkopfes durch Metallspritzer verschmutzt werden. Um die Effizienz zu maximieren und mit hohen Geschwindigkeiten fahren zu können, ist daher eine Prozessüberwachung notwendig,

die Störungen im Prozess frühzeitig erkennt und die Basis für daraus abgeleitete Reaktionen bildet.



Abbildung 1.1: Laserschneidprozess während eines Schnittabbruchs

In diesem Artikel wird die Entwicklung eines Machine Learning Modells zur Klassifikation von Prozessfehlern beim Laserschneiden beschrieben. Die Aufgabenstellung ist so gesetzt, dass zwischen geschnitten und ungeschnitten Beispielen differenziert werden soll. Dazu wird in Abschnitt 1 beschrieben wie Daten aus dem Laser Blanking Prozessen gesammelt und vorverarbeitet werden. Hierbei wird das Lasersignal moduliert, wodurch kurze Perioden entstehen die als Impulsantwort des Prozesses analysiert werden können. Eine besondere Herausforderung ist dabei, dass die Datensätze unausgewogen sind, was das Modelltraining erschwert (Abschnitt 2). In Abschnitt 3 und 4 werden diverse Methoden zur Merkmalerstellung, sowie Deep Learning Methoden zur Klassifizierung verglichen. Der Artikel endet mit einer Zusammenfassung und einem qualitativen Vergleich.

1. Der Datensatz: die Grundlage jedes maschinellen Lernens

Der Erfolg jedes Algorithmus des maschinellen Lernens steht und fällt mit einem guten Datensatz. Für dieses Projekt wurde ein Datensatz erstellt, der den Prozess durch zwei Sensoren überwacht. Diese nehmen Lichtsignale im sichtbaren (VIS) und nahen Infrarotbereich (NIR) auf. Das resultierende Signal ist in Abbildung 1.2 zu sehen. Während im vorderen Bereich der Schnitt Problemfrei abläuft, kann im hinteren Bereich ein Schnittabbruch erkannt werden. Die Schnitte wurden mit der Minimal Invasiven Laser Modulation (MILM) Technik erstellt, siehe dazu Artikel 11g (Echtzeit-Prozessüberwachung beim Laserblanking). Kurz gesagt wird hier die Laserleistung mit einer Frequenz von 500 Hz geringfügig reduziert. Somit kann die Impulsantwort des Prozesses, die signifikanter mit dem Prozesszustand korreliert, ausgewertet werden. Die resultierenden Perioden sind in Abbildung 1.2 farblich gekennzeichnet.

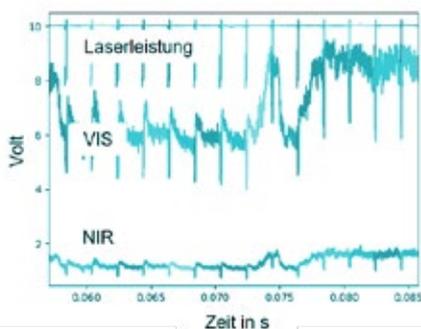


Abbildung 1.2: Signale der optischen Sensoren (VIS, NIR) und modulierte Lasersignal

Für neuronale Netze ist eine Vorverarbeitung der Eingangsdaten sinnvoll. Dazu ist ein tiefes Verständnis des Prozesses notwendig. Erfahrungen aus früheren Experimenten haben gezeigt, dass der Mittelwert des Signals in keinem universell verwertbaren Verhältnis zum Schnittabbruch steht. Dies konnte auch in unseren Experimenten bestätigt werden. Da neuronale Netze in der Regel mit normierten Daten trainiert werden, konnte nach dieser Erkenntnis der Mittelwert des Signals entfernt und das Signal periodenweise normiert werden.

Des Weiteren wurden verschiedene Techniken für das Entrauschen des Signals evaluiert. Dabei zeigte sich, dass die hohen Frequenzanteile des Signals für eine korrekte Klassifikation nicht entscheidend sind, sondern die niederfrequente Signalform die wesentliche Information enthält. Den besten Kompromiss zwischen Leistung und Geschwindigkeit bietet hierzu ein gleitendes Mittelwertfilter.

2. Unausgewogene Datensätze: ein häufiges Problem in der Produktionstechnik

Eine große Herausforderung bei der Anwendung von neuronalen Netzen sind unausgewogene Datensätze, d.h. eine Klasse ist im Datensatz unterrepräsentiert. Dies ist bei vielen Anwendungen in der Produktionstechnik der Fall. Für das Laserschneiden bedeutet dies konkret, dass ungeschnittene Beispiele nicht im gleichen Maße auftreten wie geschnittene. Nicht geschnittene Proben können zwar provoziert werden, sind aber mit erhöhtem Verschleiß und dem Risiko einer Beschädigung von Anlagenkomponenten verbunden. Im vorliegenden Versuchsdatensatz beträgt das Verhältnis von ungeschnittenen zu geschnittenen Perioden etwa eins zu fünf. Im realen Schneidebetrieb tritt das Ergebnis erheblich seltener auf.

Um dieses Problem zu lösen, wurden verschiedene Verfahren getestet. Konkret wurden für das Training synthetische Daten mit Hilfe der Synthetic Minority Oversampling Technique (SMOTE) und Adaptive Synthetic Sampling (ADASYN) erzeugt und für das Training verwendet. Außerdem wurde kostensensitives Lernen eingesetzt. Dies bedeutet, dass für die Minderheitsklasse eine höhere Lernrate verwendet wird. Eine weitere Methode, die getestet wurde, ist die zufällige Wiederholung von Beispielen der Minderheitsklasse. Diese Methode konnte die anspruchsvolleren Methoden nicht schlagen, hat aber überraschend gut funktioniert, leidet aber generell unter dem Problem der Überanpassung (Eingabe wird „auswendig gelernt“). Zusammenfassend lässt sich sagen, dass die größte Verbesserung durch kostensensitives Lernen erzielt wurde. Die Klassifikationsgenauigkeit von SMOTE ist



jedoch nur geringfügig schlechter. Interessant wäre eine Kombination der beiden Verfahren, um die Vorteile beider zu nutzen und die Schwächen gegenseitig auszugleichen.

3. Generalisierung durch Merkmalerstellung

Bei der Merkmalerstellung und -auswahl ist es wichtig, alle Facetten des Datensatzes abzubilden, um eine umfassende Analyse zu ermöglichen. Einerseits dient eine Merkmalerstellung dazu, die Dimension des Datensatzes zu reduzieren, ohne relevante Informationen zu verlieren, um eine schnelle Klassifikation zu ermöglichen. Andererseits möchte man nicht relevante Informationen aus dem Merkmalsraum entfernen, um eine bessere Generalisierung der Daten zu erreichen. Diese Generalisierung ist eine wesentliche Stärke neuronaler Netze, da sie es ihnen ermöglicht, Muster und Beziehungen in den Daten zu erkennen und diese auf neue, noch nie gesehene Daten anzuwenden. Eine gute Generalisierung und umfassende Abdeckung des Datensatzes wird erreicht, indem eine minimale Korrelation zwischen den endgültigen Merkmalen sichergestellt wird. Dies ist der Hauptkomponentenanalyse (PCA) inhärent, weshalb diese Methode der Merkmalsgenerierung in der Signalverarbeitung häufig als Benchmark verwendet wird, die es zu übertreffen gilt. Eine effektive Generalisierung ist entscheidend für die Leistungsfähigkeit neuronaler Netze, da sie deren Fähigkeit verbessert, erfolgreich auf unterschiedliche und komplexe Datensätze zu reagieren.

Um die Ergebnisse der Hauptkomponentenanalyse zu schlagen, wurden sowohl statistische Merkmale als auch Merkmale verwendet, die speziell für diesen Prozess auf der Grundlage von Domänenwissen entwickelt wurden. Zur Erzielung einer ähnlichen Selektion für die aus den Daten generierten Merkmale wurden

ein Dendrogramm und die rekursive Merkmalsselektion verglichen. Abschließend wurden die selbsterstellten Merkmale mit unterschiedlichen Selektionsmethoden sowie die PCA-Merkmale durch ein mehrlagiges Perzeptron klassifiziert und verglichen. Die Klassifikationsgenauigkeit der beiden Selektionsmethoden unterschied sich statistisch nicht signifikant und auch insgesamt konnte weder durch die Hauptkomponentenanalyse noch durch die selbst generierten Merkmale eine Verbesserung gegenüber den durch das Faltungsnetz entworfenen Filtern (Abschnitt 4) erreicht werden.

4. Welcher Klassifikationsalgorithmus ist für Zeitreihen geeignet?

Bei der Wahl des Klassifikationsalgorithmus müssen sowohl die Eigenschaften des Ausgangssignals als auch die gewünschte Ausgabe berücksichtigt werden. Um eine ausreichend schnelle Reaktion auf das Analyseergebnis während des Prozessbetriebs zu realisieren wird eine Klassifikation von weniger als einer Millisekunde angestrebt. Um die gewünschte Klassifikationszeit bei begrenzter Rechenleistung zu gewährleisten, wurde entschieden, nur die momentane Periode zu analysieren. Die verwendeten Signalabschnitte sind Perioden äquivalenter Länge. Für solche stationären, nichtlinearen Signale konstanter Länge kann eine Vielzahl von Klassifikationsmodellen in Betracht gezogen werden. Obwohl Zeitsignale vorliegen, ist es hier nicht notwendig, rekursive neuronale Netze zu verwenden.

Hier werden die Ergebnisse eines random forests, eines mehrlagigen Perzeptrons und eines Faltungsnetzwerks verglichen. Der besondere Vorteil des random Forest ist, dass die Anzahl der Parameter und damit die Klassifikationsgeschwindigkeit sehr variabel an-



Modell	Genauigkeit	F ₁ Score	TP	FN
			FP	TN
Random Forest	97,0%	0,934	3012	45
			72	835
Mehrlagiges Perzeptron	93,0%	0,857	2868	189
			85	822
Faltungsnetzwerk	97,9%	0,956	2995	62
			19	888

gepasst werden kann, womit meist nur eine minimale Veränderung der Genauigkeit einhergeht. Außerdem kann dieser Algorithmus sehr gut mit Überanpassung umgehen. Das mehrlagige Perzeptron mit einer Hauptkomponentenanalyse als Vorverarbeitung kann als Ausgangsbasis angesehen werden, wenn man neuronale Netze in Betracht zieht.

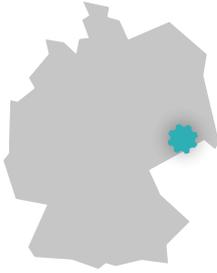
Ein Faltungsnetzwerk ist mit dem mehrlagigen Perzeptron vergleichbar, mit dem Unterschied, dass die Merkmale in diesem Fall nicht vorab extrahiert werden, sondern mit Hilfe einer Faltungsoperation aus dem Gesamtsignal erzeugt und während des Trainings angepasst werden. Faltungsoperationen eignen sich besonders für Zeitreihen sowie für Bilddaten, da sie es dem neuronalen Netz ermöglichen, benachbarte Werte miteinander in Beziehung zu setzen. Faltungsnetzwerke sind bei Bilddaten sehr beliebt, da das neuronale Netz durch die Faltungsoperation in der Lage ist, den örtlichen Zusammenhang benachbarter Pixel herzustellen und entsprechende Filter zu erstellen. Bei Zeitreihen wird diese Eigenschaft genutzt, um den zeitlichen Verlauf sowie den Zusammenhang zwischen zwei parallel aufgenommenen Zeitreihen durch das neuronale Netz darzustellen.

Die besten Ergebnisse lieferte das Faltungsnetz. Die Gesamtergebnisse sind in Tabelle 1 dargestellt. Als Bewertungskriterium wurde neben der Genauigkeit auch der F1-Score herangezogen. Dieser ist besonders für unbalancierte Datensätze geeignet, da er sowohl die Präzision (Anteil der korrekt als positiv klassifizierten Beispiele aller korrekt klassifizierten Beispiele) als auch den Recall (Anteil der korrekt als positiv klassifizierten Beispiele aller positiven Beispiele) berücksichtigt.

Tabelle 1: Klassifikationsergebnisse (geschnitten positiv, nicht geschnitten negativ)

5. Fazit

Zusammenfassend kann gesagt werden, dass mit einem Faltungsnetz eine schnelle Klassifikation des Prozesszustands möglich ist, wobei gegenüber einfachen Verfahren wie z.B. Entscheidungsbäumen signifikante Verbesserungen erzielt werden können. Während Verfahren zur Erzeugung generalisierter Merkmale keinen zusätzlichen Vorteil gegenüber den mittelwertbefreiten Daten brachte, zeigten die Ansätze zur synthetischen Datengenerierung und Ergänzungen im Lernprozess durch kostensensitives Lernen signifikante Verbesserungen. Letztendlich kann die Klassifikation einer Periode innerhalb von ca. 0,8 Millisekunden auf einem compact RIO-System durchgeführt werden. CRIO ist eine modulare Steuerungsplattform von National Instruments, die Echtzeitverarbeitung unterstützt und als Standard für Embedded-Controller-Anwendungen in der Industrie angesehen werden kann. Um ungewollte Eingriffe in den Prozess zu vermeiden, wurde abschließend eine Hysterese in dem Regulationssystem eingesetzt, so dass erst bei drei aufeinander folgenden ‚nicht geschnitten‘ Klassifikationen in den Prozess eingegriffen wird, vgl. Artikel 11g. Insgesamt konnte das Potential des maschinellen Lernens zur Absicherung und Optimierung eines komplexen Produktionsprozesses anhand des Laserschneidens gezeigt werden.



EFFIZIENTES STÖRUNGSMANAGEMENT MIT CAUSAL AI

Sven Pieper, Carl Willy Mehling (Fraunhofer IWU); Fabian Kittel (KAMAX Tools Equipment GmbH & Co. KG); Philipp Riegelmann, Matthes Winkler (queo GmbH)

CAUSAL AI beschleunigt die Behebung ungeplanter Produktionsstillstände und steigert die Maschinenverfügbarkeit. Eingebettet in ein Assistenzsystem, unterstützt CAUSAL AI die Fehlerdiagnose durch kontextspezifische Priorisierung und Ursachenbestimmung und ermöglicht eine effektive Störungsbehebung.

Ungeplante Produktionsstillstände reduzieren die Verfügbarkeit der Maschinen und stören damit empfindlich die Gesamtanlageneffektivität. Verursacht durch technische Defekte, Materialengpässe oder falsche Konfigurationen sind solche Unterbrechungen besonders in hochautomatisierten Anlagen kostspielig und deren Behebung zeitaufwendig. Die Komplexität dieser Anlagen, bestehend aus zahlreichen Maschinen und Softwarekomponenten, erschwert die schnelle Identifikation und Behebung von Fehlern.

Für die Behebung komplexer Fehlerszenarien in den automatisiert betriebenen Anlagen ist interdisziplinäre Expertise erforderlich, die sich häufig auf viele Köpfe verteilt und nicht unmittelbar im Fehlerfall zur Verfügung steht. Ein Team von Technikern, Ingenieuren und IT-Spezialisten dauerhaft vorzuhalten, ist für die meisten Unternehmen aufgrund des Fachkräftemangels schlichtweg weder wirtschaftlich noch möglich. Sind die richtigen Köpfe für den Fehlerfall versammelt, müssen diese in der Regel manuell die Fehlerquelle ermitteln und beheben, was sowohl zeitintensiv als auch teuer ist. Die Vielzahl möglicher Fehlerquellen und das

notwendige tiefe Wissen über das gesamte System stellen eine hohe Herausforderung dar, insbesondere für Personen, die viele Anlagen gleichzeitig betreuen müssen. Zudem fehlt oft die Zeit für eine detaillierte Datenanalyse und die Aufbereitung erfolgreicher Lösungen, wodurch wertvolles Wissen verloren geht und Daten nicht genutzt werden.

Trotz des dringenden Bedarfs an effizienten Diagnose- und Assistenzsystemen sind solche Systeme in der Praxis selten eingesetzt. Bestehende Methoden erfordern oft eine starke Anpassung an die jeweilige Anlage, eine hohe Rechenleistung oder eine Vielzahl zeitaufwendiger Benutzereingaben. Zudem fehlt den existierenden Systemen die Flexibilität, um sich an ständig ändernde Produktionsbedingungen anzupassen und mit dem Prozess mitzulernen. Ein weiteres Hindernis ist die mangelnde Akzeptanz und das Vertrauen der Nutzenden in diese Systeme, insbesondere auf dem Shopfloor.

Im nachfolgenden Artikel wird das im KausalAssist-Projekt entwickelte CAUSAL-AI-Assistenzsystem am Beispiel der Anwendung beim Projektpartner KAMAX Tools & Equipment vorgestellt. KAMAX fertigt hochfeste Verbindungselemente für die Automobilindustrie. Am Stammsitz in Homberg (Ohm) werden neben dem Endprodukt auch die Werkzeugsätze in Losgröße 1 in einem hochautomatisierten Prozess gefertigt. Mit dem innovativen Automatisierungskonzept konnte



die Lieferzeit von Werkzeugen bereits von mehreren Wochen auf einige Stunden reduziert werden. Durch den Einsatz von CAUSAL AI soll nun die Maschinenverfügbarkeit und Ausbringung der Anlage nochmals gesteigert werden.

CAUSAL AI ermöglicht transparente Diagnose

Das auf CAUSAL AI basierende System adressiert die Herausforderungen der hochautomatisierten Produktion. Es verwendet kausale Graphen, um Maschinenmeldungen effizient zu analysieren und deren Ursachen zu identifizieren. Dies ermöglicht eine schnelle und präzise Fehlerdiagnose sowie die Priorisierung von Maßnahmen zur Fehlerbehebung. Der kausale Graph ist einfach zu verstehen und bildet alle Annahmen transparent ab, sodass alle darauf basierenden Empfehlungen für den Menschen einfach nachvollzogen werden können. Durch die Kombination von datengetriebenen Analysen und Expertenwissen wird die Genauigkeit der Diagnosen verbessert und ungeplante Stillstandszeiten signifikant reduziert. Dies führt zu einer höheren Effizienz und Produktivität der Produktionsanlagen.

Ein weiterer Vorteil des Systems ist die Möglichkeit, kontinuierlich aus neuen Daten zu lernen und sich an veränderte Bedingungen anzupassen. Dies bedeutet, dass das System stets auf dem neuesten Stand bleibt und mit den Entwicklungen und Herausforderungen in der Produktion Schritt hält. Dadurch werden die langfristige Zuverlässigkeit und Leistungsfähigkeit der Produktionsanlagen sichergestellt.

CAUSAL AI: Die Grundlagen

Ein kausaler Graph, siehe Zentrum Abbildung 1, stellt kausale Beziehungen zwischen verschiedenen Variablen dar. Variablen sind als Knoten und kausale Verbindungen als gerichtete Kanten von Ursache zu Effekt dargestellt. Kausale Graphen helfen, kausale Zusammenhänge in einem System leicht verständlich abzubilden und zu visualisieren.

Kausale Graphen ermöglichen die Identifikation und Analyse von Ursache-Wirkungs-Beziehungen in komplexen Systemen. Sie sind besonders nützlich für die Fehlerdiagnose, da sie helfen, die Ursprünge von Problemen zu finden und deren Auswirkungen zu verstehen. In Produktionsumgebungen können sie beispielsweise eingesetzt werden, um festzustellen, welche Maschine in einem Produktionsprozess eine Störung verursacht hat und welche Ursachen dafür in Frage kommen.

Diese Graphen werden üblicherweise durch Expertenwissen oder datengetriebene Ansätze erstellt. Die manuelle Erstellung erweist sich oft als sehr aufwendig und fehleranfällig. Maschinelles Lernen kann hier unterstützen, indem kausale Beziehungen aus aufgezeichneten Produktionsdaten vorgeschlagen und kontinuierlich verbessert werden. Dies spart Zeit und erhöht die Genauigkeit der Fehlerdiagnose.

Das maschinelle Lernen von kausalen Zusammenhängen wird als Kausalentdeckung (Causal Discovery) bezeichnet. Causal Discovery nutzt Methoden und Algorithmen, um kausale Abhängigkeiten und Unabhängigkeiten zwischen Variablen in einem Datensatz zu identifizieren. In der Produktionsumgebung bedeutet dies, dass Zeitreihendaten aus Maschinendaten, Softwarelogs und anderen relevanten Quellen analysiert werden, um kausale Zusammenhänge von Korrelation zu unterscheiden. Dieser datengetriebene Ansatz wird durch Expertenwissen ergänzt, um sicherzustellen, dass die Graphen die tatsächlichen Prozesse und Abhängigkeiten möglichst genau widerspiegeln.

Anwendung für Fehlerdiagnose, Fehlerpriorisierung und Ursachenanalyse

Das KI-gestützte Diagnosesystem analysiert eingehende Fehlermeldungen und priorisiert diese hinsichtlich ihres Schweregrads für die Produktion und hinsichtlich der Ursächlichkeit für Stillstände. Dies hilft Technikern, sich auf die kritischen Probleme zu

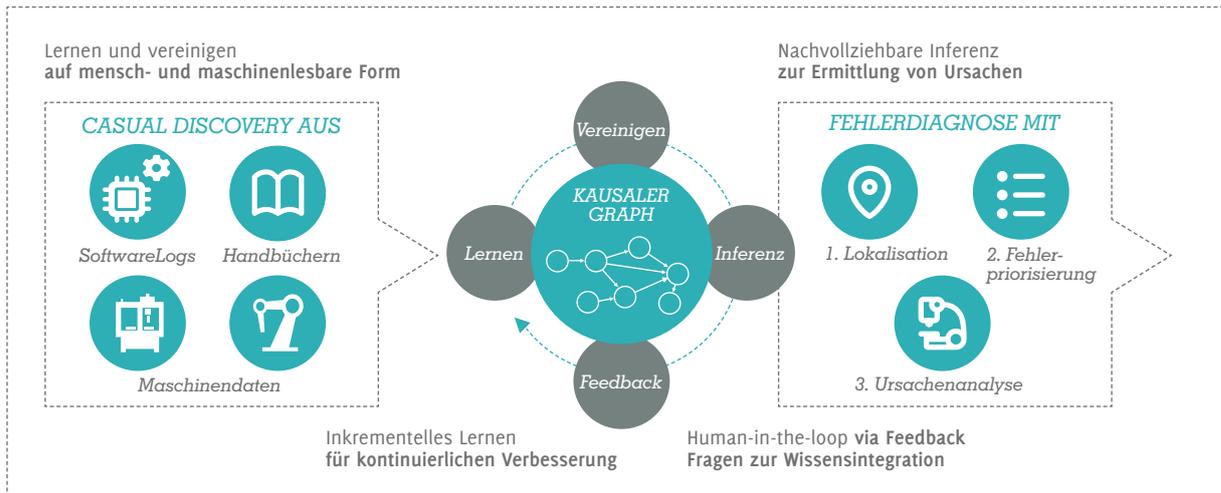


Abb. 1: Prozessübersicht des kausalen Lernsystems. Der zentrale kausale Graph nutzt Daten aus Software-Logs, Maschinendaten und Handbüchern. Der Lernzyklus umfasst das Lernen und Vereinen von Informationen, nachvollziehbare Inferenz zur Ursachenermittlung, Fehlermeldung und inkrementelles Lernen. Die Fehlerdiagnose beinhaltet Lokalisierung, Fehlerpriorisierung und Ursachenanalyse, unterstützt durch Human-in-the-loop für kontinuierliche Wissensintegration.

konzentrieren und diese an der Wurzel zu beheben. Die Fähigkeit, den Schweregrad und potenzielle Auswirkungen der Fehler zu bewerten, ermöglicht eine schnelle Fehlerbehebung und Wiederanlauf der Produktion.

Nachdem die Fehler priorisiert wurden, analysiert das System den aktuellen Maschinenzustand, um mittels des kausalen Graphen die wahrscheinlichste Ursache im aktuellen Kontext zu identifizieren. Passend zur aktuellen Situation werden Lösungsvorschläge unterbreitet, die den Technikern helfen, die Probleme effizient zu beheben. Diese Vorschläge basieren auf eingespeicherten Lösungen, die anhand der automatischen Ursachenanalyse jeweils kontextspezifisch gewichtet und priorisiert werden. Die Kombination aus datengetriebener Analyse und Expertenwissen verbessert die Nutzerakzeptanz und erhöht die Erfolgsquote der vorgeschlagenen Lösungen. Eine in Lösungsschritte gegliederte und mit Bildern angereicherte Darstellung des Lösungsvorschlags ermöglicht eine schrittweise

Bearbeitung der Aufgabenstellung. Durch die Möglichkeit, Rückmeldungen zu Aufbau und Inhalt einer Lösung zu geben, kann eine kontinuierliche Verbesserung der Lösungsstrategien erreicht werden. Erfolgreiche Lösungen werden in Zukunft im jeweiligen Kontext bevorzugt angeboten und fehlgeschlagene Lösungen zurückgestuft, was zu einer kontinuierlichen Verbesserung im Betrieb führt.

Kombination von Daten und Produktionswissen

Das System wird durch neue Produktionsdaten und Benutzereingaben in einem kontinuierlichen Lernprozess ständig verbessert. Es integriert Sensordaten und Maschinenevents, die mit OPC UA zentral gesammelt werden, um ein umfassendes Bild der Produktionsprozesse zu erstellen. Diese Integration ermöglicht eine präzise und aktuelle Überwachung der gesamten Produktionslinie und hilft, potenzielle Probleme frühzeitig zu erkennen und direkt zu adressieren.

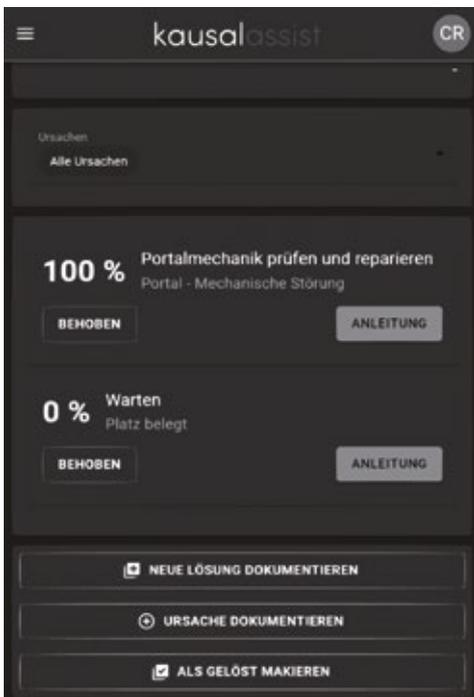


Abb. 2: Screenshot der Shopfloor GUI mit Lösungsvorschlägen zur Behebung des Portalstillstands. Konkretere Lösungsschritte befinden sich jeweils innerhalb der Lösungsanleitung.

Expertenwissen wird durch Wissensdatenbanken, interaktive Schnittstellen und kontinuierliches Feedback in das System integriert. Dies erhöht die Genauigkeit der Diagnosen und die Effizienz der Fehlerbehebung. Durch diese Kombination aus Daten und Expertenwissen kann das System nicht nur Probleme identifizieren und beheben, sondern auch wertvolle Erkenntnisse für die Verbesserung der Produktionsprozesse bieten. Dies fördert zudem ein tieferes Verständnis der gesamten Produktionslinie.

Auswirkung von CAUSAL AI am Beispiel von KAMAX

KAMAX betreibt eine hochvernetzte Produktionsanlage, die Software- und Maschinenautomatisierung ganzheitlich kombiniert. Diese Anlage ist mit zahlreichen Sensoren und Automatisierungssystemen ausgestattet, die Daten in Echtzeit liefern. Ein zentraler Leitrechner koordiniert die Aufgaben und überwacht den Produktionsablauf, während das MES (Manufacturing Execution System) die Produktionsprozesse

steuert und mit dem ERP(Enterprise Resource Planning)-System kommuniziert.

Aufgrund dieser hohen Vernetzung der Produktionsanlage treten Probleme auf, die auf den ersten Blick schwer zu identifizieren sind, da die Maschinen und Systeme eng miteinander verbunden sind. Wenn eine Maschine in den ungeplanten Stillstand gerät, können die Ursache und die Auswirkungen komplex sein und sich auf die gesamte Produktionslinie auswirken. Der Werker muss dann die Fehlerquelle manuell suchen, was zeitaufwendig ist und Stillstandszeiten verlängert. Ein Beispiel für häufige Probleme ist der Stillstand des Portalroboters, der Bauteile zwischen den Maschinen transportiert. Ein solcher Stillstand kann durch mechanische Probleme oder einen vollen Pufferplatz verursacht werden. Beide Ursachen können zu einem Stillstand der gesamten Produktionslinie führen, da die anderen Maschinen auf die Bereitstellung und den Abtransport der Teile angewiesen sind.

Der KausalAssist Stack bei KAMAX sammelt alle Maschinenevents und ausgewählte Produktionsdaten via OPC UA. Die Daten werden von Causal Discovery Methoden genutzt, um kausale Zusammenhänge zu erlernen. Alle Ergebnisse werden fortlaufend in einem gemeinsamen kausalen Graphen der Produktionsanlage konsolidiert.

Das CAUSAL-AI-System analysiert die aktuellen Fehler- und Maschinenevents, um kritische Fehler zu identifizieren und zu priorisieren. Mithilfe des erlernten kausalen Graphen werden die primären Ursachen für Stillstände zwischen weiteren Meldungen erkannt. Das System bietet basierend auf der Ursachenanalyse



konkrete Lösungsvorschläge an, die entweder aus früheren erfolgreichen Behebungen und/oder aus dem kausalen Graphen abgeleitet sind (siehe Abbildung 2). Der Werker setzt diese vorgeschlagenen Lösungen um und überwacht den Fortschritt sowie die Auswirkung der Maßnahme in Echtzeit.

Durch den Einsatz des Systems soll bei KAMAX die Ausbringung und Verfügbarkeit der Anlage gesteigert werden, indem Produktionsunterbrechungen und längere ungeplante Stillstände reduziert werden. Die gesammelten Daten, Erfahrungen und das Feedback der Werker tragen zur kontinuierlichen Verbesserung des kausalen Graphen bei, wodurch zukünftige Probleme noch zielgerichteter gelöst werden sollen.

Fazit

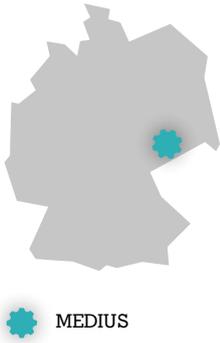
Die Implementierung von CAUSAL AI bietet erhebliche Vorteile für hochautomatisierte Produktionsanlagen. Durch die rasche Identifikation und Priorisierung von Fehlern sowie die präzise Ursachenanalyse können ungeplante Stillstandszeiten signifikant reduziert werden. Das System nutzt Sensordaten und Maschinen-events, kontinuierliches Lernen und Expertenwissen, um effizientere und effektivere Lösungen für auftretende Probleme zu ermöglichen.

Die Einführung dieses intelligenten Systems kann zu einer merklichen Steigerung der Produktionsleis-

tung führen. Durch die Reduzierung der ungeplanten Stillstandszeiten können Maschinen länger und zuverlässiger betrieben werden, was zu einer höheren Ausbringung führt. Die Fähigkeit, schnell auf Fehler zu reagieren und diese zu beheben, kann sowohl die Effizienz als auch die Qualität der Produktion erheblich verbessern.

Produzierende Unternehmen können durch den Einsatz von CAUSAL AI bedeutende Fortschritte in Richtung Smart Factory und digitaler Transformation erzielen. Die Kombination aus fortschrittlichen Analysetechniken, kontinuierlichem Lernen und der Integration von Expertenwissen stellt sicher, dass Produktionsanlagen effizient und zukunftssicher betrieben werden können. Langfristig profitieren Unternehmen nicht nur von gesteigerter Produktionseffizienz, sondern auch von einer verbesserten Qualität und Zuverlässigkeit ihrer Produkte.

Die Fähigkeit des Systems, sich kontinuierlich an neue Daten und Bedingungen anzupassen, garantiert, dass Unternehmen stets auf dem neuesten Stand der Technologie bleiben und ihre Produktionsprozesse optimieren können. Dies führt zu einer nachhaltigen Verbesserung der betrieblichen Abläufe und stärkt die Wettbewerbsfähigkeit auf dem Markt.



CYBERPHYSISCHE LASERTECHNOLOGIE IN DER MIKROLASER- BEARBEITUNG

Tobias Steege (Fraunhofer IWS, MEDIUS)

Mithilfe von KI und Augmented Reality können Laserfertigungsprozesse revolutioniert und die Zusammenarbeit zwischen Mensch und Maschine optimiert werden.

Der Einsatz von Laserstrahlung als Werkzeug hat sich in der industriellen Produktion etabliert und zu einem Wandel geführt, bei dem klassische Fertigungsverfahren durch laserbasierte Prozesse ersetzt wurden. Lasertechnologien sind zusätzlich gut digitalisierbar, sodass Automatisierungsszenarien und selbstregelnde Prozesse ermöglicht werden können. Laserprozesse sind jedoch meist komplex und erfordern spezifisches ingenieurwissenschaftliches Domänenwissen sowie langjährige Erfahrung, um optimale Prozessergebnisse zu erreichen. Die komplexen und zeitintensiven Konfigurations- und Entscheidungsprozesse und die Auswahl optimaler Prozessparameter lassen sich durch den Einsatz KI-basierter Vorhersagesysteme in Kombination mit intuitiven Mensch-Maschine-Interaktionen vereinfachen und ersetzen. Die Virtualisierung verändert die Rolle des Menschen als Bediener der Maschine, wobei AR-Technologien und KI-basierte Systeme eingesetzt werden, um Fehlerraten zu reduzieren, Arbeitsgeschwindigkeiten zu erhöhen und Lernprozesse zu vereinfachen. AR-Systeme kommen bereits in logistischen Prozessen zur Anwendung, aber die Maschinensteuerung über neue Bedienkonzepte und KI-basierte Gestensteuerungen ist noch neu.

Untersuchungen zu AR-Technologien sollen die kognitive Belastung des Menschen verringern und dessen Arbeitseffizienz erhöhen.

Im Projekt MEDIUS haben sich Experten aus den Bereichen Lasertechnologie, Künstliche Intelligenz, Mensch-Maschine-Interaktion, Datenkommunikation und Oberflächenmesstechnik zusammengetan. Ihre spannende Vision: Eine Laserfertigungstechnologie zu entwickeln, die auf direkter Laserinterferenz basiert und durch Augmented Reality (AR) unterstützt wird. Mithilfe einer KI-basierten lernenden Plattform wollen sie die Steuerung der Laserprozess-technik so intuitiv und effizient wie möglich gestalten. Ziel ist es, eine smarte Produktionsumgebung zu schaffen, die Oberflächen auf völlig neue Weise funktionalisiert und dabei die Zusammenarbeit von Mensch und Maschine revolutioniert.

Cyberphysische Lasertechnologie

Cyberphysische Lasertechnologie zielt darauf ab, Laserfertigungsprozesse durch moderne Daten- und KI-Technologien effizienter und intelligenter zu gestalten. Dabei wurde die zentrale Low-Code-Integrationssoftware Transconnect eingesetzt, um Daten aus verschiedenen Maschinen und Überwachungssystemen über Adapter anzubinden. Dadurch entsteht eine zentrale Schnittstelle (Single Point of Truth), die alle relevanten Maschinendaten speichert, transformiert und für maschinelle Lernverfahren nutzbar macht.

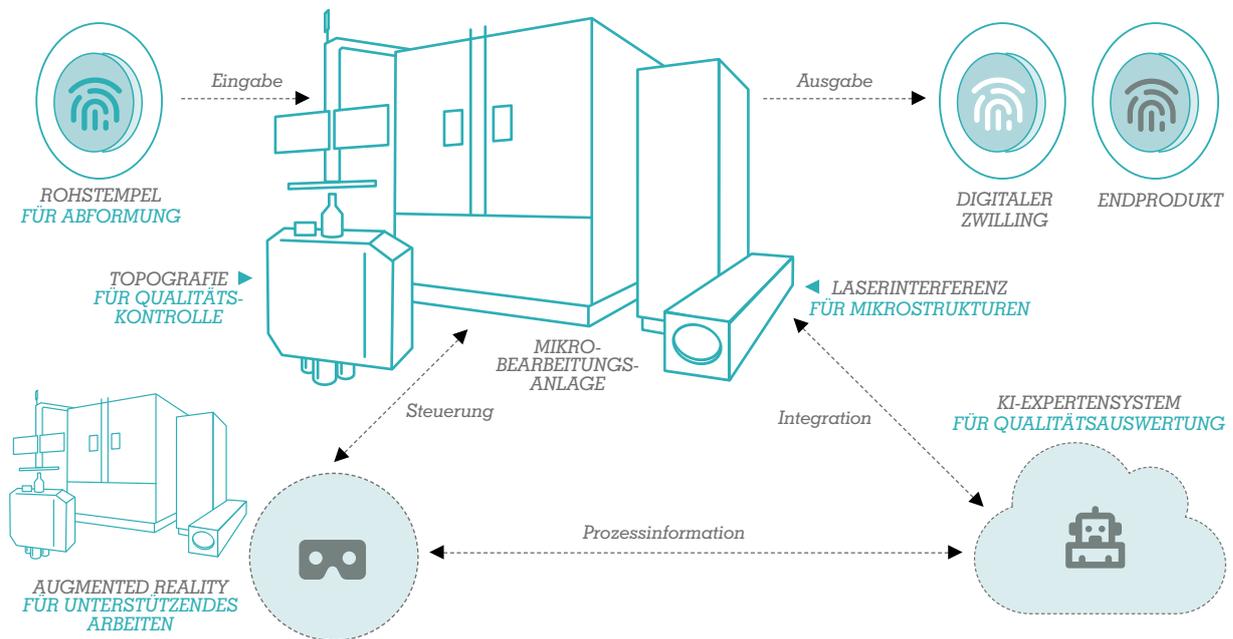


Abb. 1: Zusammenspiel der einzelnen Systeme in der Lasermaschine im Rahmen des Projektes MEDIUS

Der Vorteil der zentralen Plattform besteht darin, dass die bestehenden Schnittstellen zu den einzelnen Komponenten der Partner genutzt werden können, wodurch individuelle Anpassungen reduziert werden. Dies ermöglicht die Automatisierung von Produktionsprozessen, eine schnellere Fehlererkennung und eine optimierte Zusammenarbeit zwischen Mensch und Maschine. Das Ziel ist es, eine intelligente, lernende Produktionsumgebung zu schaffen, die Oberflächen effizient und innovativ bearbeitet.

Die Abbildung 1 zeigt das Zusammenspiel der einzelnen Systeme in der Lasermaschine für die Mikrostrukturierung, die mit einem Weißlichtinterferometer zur Vermessung der Topografie der finalen Proben ausgestattet ist. Diese Proben werden mit einem Laserinterferenzmodul hergestellt. Nach der Bearbeitung wird die Topografie der Proben vermessen und zusammen mit den Prozessdaten des Interferenzmoduls an das zentrale KI-Expertensystem weitergeleitet. Dabei werden die Strukturen der Proben direkt ausgewertet und bieten somit eine umfassende Qualitätskontrolle. Ein besonderes Merkmal ist die Integration von Augmented Reality (AR) für unterstützendes Arbeiten. Nutzen können eine AR-Brille verwenden, um die finale

Auswertung der Proben direkt durchzuführen. Die AR-Brille zeigt in Echtzeit alle relevanten Prozessinformationen an und ermöglicht eine intuitive Interaktion mit dem System. Alle relevanten Prozessparameter werden kontinuierlich an das zentrale KI-Expertensystem übermittelt, das die Daten analysiert und zur Beurteilung der Strukturen verwendet. Das Endprodukt wird dann als digitaler Zwilling ausgegeben, der eine präzise virtuelle Repräsentation der physischen Proben bietet. Dieses digitale Modell dient sowohl der Qualitätskontrolle als auch der weiteren Optimierung der Produktionsprozesse. Zusammengefasst ermöglicht dieses System eine intelligente, vernetzte Produktionsumgebung, die durch die Kombination von Lasertechnologie, AR und KI zu effizienteren und präziseren Bearbeitungsergebnissen führt.

Cyberphisches DLIP-Modul

Die direkte Laserinterferenzstrukturierung (DLIP) wird zur Strukturierung von Stempeln eingesetzt, um periodische Mikro- und Nanostrukturen auf Oberflächen zu erzeugen. Dabei werden zwei oder mehr Laserstrahlen in einem definierten Winkel überlagert, um Interferenzmuster zu bilden. Je nach Anzahl der Strahlen können Linien- (2-Strahl-DLIP) oder



Punktstrukturen (4-Strahl-DLIP) erzeugt werden. Ein DLIP-Modul wird in die Lasermaschine des Projektpartners Pulsar Photonics integriert und weiterentwickelt, um automatisches Wechseln der Strahlenanzahl, unabhängige Strahlenführung von Maschinenachsen und das Auslesen des Modulzustands über ein zentrales System zu ermöglichen.

Ein Strahlenteilerwechsler für die optischen Elemente erlaubt es, bis zu drei optische Elemente im Strahlenpfad zu platzieren und zwischen verschiedenen Strahlenteilungsmodi zu wechseln. Der Cyclops-2D-Scanner ermöglicht die Bearbeitung einer Fläche von 20 mm ohne Bewegung des Probenhalters. Experimente bestätigten die Funktionalität des Systems, das ohne Leistungsverlust zwischen 2-Strahl-, 3-Strahl- und 1-Strahl-Modus wechseln kann

Akustisches Prozessmonitoring

Parallel zur Entwicklung des cyberphysischen DLIP-Moduls wurde ein Monitoring-Modul entwickelt, das sowohl akustische Aufnahmen des Prozesses als auch das Prozessleuchten mittels einer Diode und Kamera aufnimmt. Das Herzstück des akustischen Monitoring-Moduls sind speziell ausgewählte MEMS-Mikrofone, die aufgrund ihrer geringen Größe und geeigneten Eigenschaften für die Aufnahme von Laser-Akustikemissionen in den relevanten Frequenzbereichen ausgewählt wurden.

Anfangs wurden verschiedene Messmikrofone mit unterschiedlichen Frequenzbereichen getestet, um die optimale Lösung für die Aufzeichnung der Prozessemissionen zu finden. Diese Tests dienten auch dazu, die Nachbearbeitung und Qualitätsbestimmung zu entwickeln sowie Daten für das Antrainieren der KI-Algorithmen zu sammeln. Durch kontinuierliche Iterationen und Anpassungen der Hardware wurde die aufzeichnungsfähige Frequenzgrenze schrittweise erhöht, mit dem Ziel, Ultrakurzpulslaser mit hohen Wiederholungsraten überwachen zu können. Letztendlich fiel die Wahl auf MEMS-Mikrofone, die eine Aufzeichnung von Frequenzen bis zu 192 kHz ermöglichen. Für verschiedene Oberflächentexturen wurde ein

Datensatz von Einzelpulsen erstellt und analysiert. Mit verschiedenen maschinellen Lernmodellen (Support Vector Machine, K-nearest neighbors, Random Forest und neuronales Netz) konnte die räumliche Periode einer texturierten Oberfläche mit einer Genauigkeit von bis zu 95 % vorhergesagt werden.

Augmented-Reality-System

Das entwickelte holografische dreidimensionale Augmented-Reality(AR)-System dient als digitales Assistenzsystem für die Maschinenbedienung und Anlagensteuerung bei der Lasermikromaterialbearbeitung. Ein „visueller Zwilling“ der physischen Laseranlage wird auf Basis von CAD-Daten erstellt und mit den Maschinen- und Prozessdaten verknüpft. Ergänzt durch topografische Oberflächenvisualisierungen, wird dieser digitale Zwilling holografisch dargestellt. Die AR-Technologie ermöglicht es, Informationen, Daten, Anweisungen, Systemzustände, Warnungen und Abbildungen direkt an der physischen Anlage oder über eine visuelle Überlagerung darzustellen, wodurch die Arbeitsabläufe und die Prozessübersicht für den Bediener verbessert werden.

Anwendungen bei einer Lasermaschine

Der Fokus lag auf der Entwicklung eines Anwendungsfalls und eines Anforderungskatalogs für ein Augmented-Reality(AR)-System, die Nutzung einer Laserbearbeitungsmaschine unterstützt. Dafür wurden fünf Szenarien definiert:

Objektbezogene Kommunikation: Ein 3D-Modell der Laserbearbeitungsmaschine oder einer wesentlichen Komponente wird in AR besprochen. Diese Anwendung ermöglicht mehreren räumlich verteilten Nutzern, gemeinsam zu kommunizieren, was nützlich für Produktservice und Entwicklung ist.

Einrichtung & Kalibrierung der Maschine: AR hilft bei der Einrichtung und Kalibrierung, indem es Messdaten und Parameter visuell darstellt, während Testfelder auf einer Probe erstellt werden.

Montage eines Strahlumlenkers: Dieser Prozess, der oft von Auszubildenden durchgeführt wird, profitiert von AR-Unterstützung. Es erleichtert das Einlernen neuen Personals durch visuelle Anleitungen.

Montage eines Strahlformers: Ähnlich wie bei der Strahlumlenkermontage, jedoch komplexer. Hier wird untersucht, wie gut AR bei der Montage und Justage komplexer Bauteile hilft.

Steuerung der Maschine: AR unterstützt das Bedienpersonal, indem es prozessbezogene Informationen in einer AR-Brille darstellt. Die Steuerung erfolgt über Gesten oder virtuelle Schaltflächen, welche die Eingaben in Maschinenbefehle umsetzen.

Diese Szenarien zeigen, wie AR die Arbeitsabläufe bei der Nutzung und Wartung von Laserbearbeitungsmaschinen erleichtern und effizienter gestalten kann (siehe Abbildung 1).

Kognitive Belastungen in Mixed-Reality-Umgebung

Das AR-System zeigt interaktive holografische Steuerungselemente, die nur die für die jeweilige Situation erforderlichen Informationen darstellen. Die Komplexität kann vom Bediener angepasst werden.

Zu den wesentlichen Arbeitselementen gehören die Auswahl geeigneter AR-Hardware, die Schnittstellendefinition zu anderen Teilsystemen, die Gestaltung einer Softwareplattform, die Spezifizierung einer AR-Mensch-Maschine-Schnittstelle sowie die Definition von Evaluationskriterien für Nutzerzufriedenheit und Komfort.

Es wird die notwendige Software für die AR-Visualisierung und Mensch-Maschine-Interaktion entwickelt, einschließlich der KI für intuitive Gestensteuerung. Die relevanten Komponenten werden vor der Systemintegration entwickelt und getestet. Zudem werden kognitive Belastungsszenarien und die sensorbasierte Erfassung kognitiver und affektiver physiologischer Daten am AR-System evaluiert.

Das DFKI misst die kognitive Belastung von Nutzern bei der Verwendung einer Mixed-Reality-Anwendung, sei es beim Zusammenbau physischer Objekte wie eines Strahlumlenkers oder bei Arbeiten an einer Laseranlage. Dafür werden kontinuierlich physiologische Daten von Probanden mittels des intelligenten Armbands Empatica EmbracePlus sowie die Augenbewegung durch die Microsoft HoloLens 2 aufgezeichnet. Anhand der Daten wird das Stresslevel über einen angelernten KI-Algorithmus ermittelt.

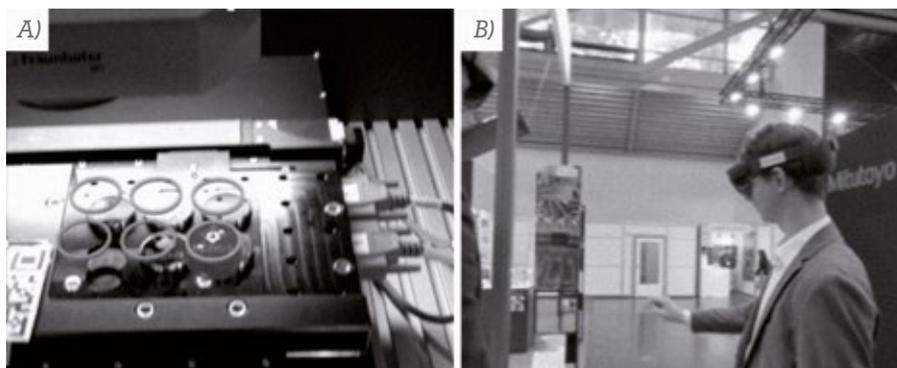


Abb. 2: Darstellung der Laseranlage in AR-Umgebung, a) Probenstück mit strukturierten Stempeln
b) Interaktion eines Nutzers innerhalb der AR-Umgebung



Prädiktives Vorhersagen von Oberflächenfunktionalitäten

Entsprechend des Anforderungskatalogs für die prädiktive Vorhersage werden Modelle auf Basis von maschinellen Lernalgorithmen entwickelt, um Oberflächenfunktionalitäten nach der Laserbearbeitung vorherzusagen. Hierbei werden spezifische Rauheitsparameter der bearbeiteten Oberflächen mit deren resultierenden Funktionalitäten wie Benetzbarkeit, Mattierung, Dekoration und Wärmetransport verknüpft. Diese Modelle ermöglichen es, beispielsweise den Wasserkontaktwinkel von laserbehandelten Materialien vorherzusagen und dadurch die Entwicklungszeiten für komplexe Oberflächen erheblich zu verkürzen. Dafür werden als Input die Prozessdaten genutzt, wobei die spezifischen Oberflächeneigenschaft jeweils die Zielparameter darstellen.

Die virtuellen Metaoberflächen, die während des Prozesses erzeugt werden, sowie die gesammelten Daten aus verschiedenen Tests werden kontinuierlich zur Verbesserung der Modelle genutzt. Diese Metaoberflächen fassen Informationen wie akustische Frequenzspektren, Plasmaleuchten und verwendete Laser- und Maschinenparameter zusammen, die dann mit den Topografiebildern der resultierenden Oberflächen korreliert werden.

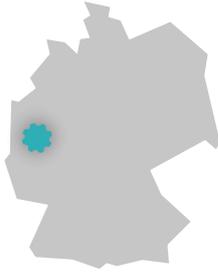
Im ersten Schritt wurde die Glanzmessung bearbeiteter Oberflächen als Testparameter gewählt, da diese direkt und einfach messbar ist. Ein Datensatz von 1000 Strukturen wurde erstellt, aus welchem topografische Parameter extrahiert wurden. Eine Pipeline zum Anlernen der Maschinenlernmodelle wurde entwickelt, wobei die Daten in Trainings- und Testsets aufgeteilt und spezifische Parameter für verschiedene Modelle wie Random Forest (RF), XGBoost (XGB) und künstliche neuronale Netze (ANN) optimiert wurden. Die Ergebnisse zeigten, dass eine Vorhersage der Oberflächeneigenschaften möglich ist, wenn die genutzten Laserparameter berücksichtigt werden.

Der trainierte RF-Algorithmus kann nun den Glanz der bearbeiteten Oberflächen mit einer Genauigkeit von 92 % vorhersagen.

Zusammenfassung und Ausblick

Das Projekt zeigt, wie die Integration von Laseranwendung, Augmented Reality (AR) und Künstliche Intelligenz (KI) in die Produktion überführt werden können. Dafür wurde eine zentrale, KI-gestützte Datenplattform entwickelt, die eine intelligente und lernende Produktionsumgebung ermöglicht, was zu einer Automatisierung der Prozesse, schnellerer Fehlererkennung und optimierter Zusammenarbeit zwischen Mensch und Maschine führt. Das cyberphysische DLIP-Modul zur Strukturierung von Oberflächen und das akustische Prozessmonitoring tragen zur Qualitätssicherung bei. Ein holografisches AR-System verbessert die Bedienung und Wartung von Maschinen, während prädiktive Modelle die Vorhersage von Oberflächenfunktionalitäten nach der Laserbearbeitung präzisieren.

Zukünftig wird die Weiterentwicklung von AR-Technologien und prädiktiven Modellen die Effizienz und Genauigkeit in der Oberflächenbearbeitung weiter steigern. Diese Entwicklungen sind ein Schritt in Richtung einer voll vernetzten autonomen Produktionsumgebung im Sinne von Industrie 4.0 und können die Fertigungstechnik grundlegend verändern, indem sie neue Möglichkeiten für die Zusammenarbeit zwischen Mensch und Maschine eröffnen.



VERSATZDETEKTION AN 3D-GEDRUCKTEN BAUTEILEN DURCH KI

Frank Weissbuch (ThetaScan GmbH), Volker Carl (ThetaScan GmbH), Dennis Jutkuhn (Fraunhofer-Einrichtung für Additive Produktionstechnologien IAPT), Dieter Weiler (Q2Web GmbH), Arne Erdmann (Raytrix GmbH)

Zur Vermeidung von qualitätskritischen Versatzeffekten bei der Herstellung von laseradditiv gefertigten Bauteilen in Multi-laser-Fertigungsanlagen wurde ein künstliches neuronales Netzwerk entwickelt und angelernt, das einen Versatz der Bauteilgeometrie in den Darstellungen der optischen Tomografie bei der in-situ-Prozessüberwachung detektiert.

Das selektive Laserstrahlschmelzen für Metalle (Laser Powder Bed Fusion for Metal, PBF-LB/M) ist ein additives Fertigungsverfahren, bei dem Metallpulver Schicht für Schicht mithilfe eines oder mehrerer Laser verschmolzen wird, um dreidimensionale Bauteile herzustellen. Durch die präzise Steuerung des Lasers können komplexe Geometrien und innere Strukturen realisiert werden. PBF-LB/M wird häufig in der Luft- und Raumfahrt, Medizintechnik und Automobilindustrie eingesetzt, um hochfeste und leichte Bauteile herzustellen. Ein Kernproblem der PBF-LB/M-Technologie sind die sehr hohen Produktionskosten im Vergleich zu konventionellen Fertigungsverfahren, wie dem Gießen und abtragenden Verfahren. Daher ist die Erkennung von Fehlstellen schon während des Fertigungsprozesses von entscheidender Bedeutung. Hierzu zählt die dauerhaft zu gewährleistende räumliche Kalibrierung der Arbeitsbereiche der Laser in Bezug zueinander, um Versatzeffekte bei Bauteilen,

die über die Scanfelder mehrerer kooperierender Laserscanner reichen, zu verhindern. Bislang wurde dies ex situ per Gravur von Kalibrierfolien gelöst, die anschließend optisch auf Versätze geprüft und in der Laserscanner-Steuerung korrigiert wurden. Dies hat den erheblichen Nachteil, dass ggf. zwischen den Kalibrierprozessen mehrere Iterationen an fehlerbehafteten Bauteilen produziert werden. Untersuchungen zeigen, dass sich auch während eines Baujobs Scanfelder aufgrund von sich verändernden thermischen und optischen Bedingungen verschieben können und entsprechend im laufenden Betrieb angepasst werden müssen. Eine permanente und prozessbegleitende Versatzkontrolle existierte bisher nicht. Aus diesem Grund wurde eine KI zur Vorhersage des Versatzes mit den Daten eines Optische-Tomografie-Systems trainiert.

Optische Tomografie (OT)

Bei der optischen Tomografie handelt es sich um eine pyrometrische Off-axis-Überwachung durch eine hochauflösende CMOS-Kamera, die außerhalb des Strahlenganges des Lasers in Off-axis-Konfiguration (vgl. Bild 1a) angeordnet ist. Dabei beobachtet das Messsystem die gesamte Baufläche oder auch nur einen Teilbereich der Baufläche. Die Vorteile der optischen Tomografie liegen in der einfachen und auch nachträglich möglichen Installation einer CMOS-Kamera außerhalb des Bauraumes und des Strahlenganges

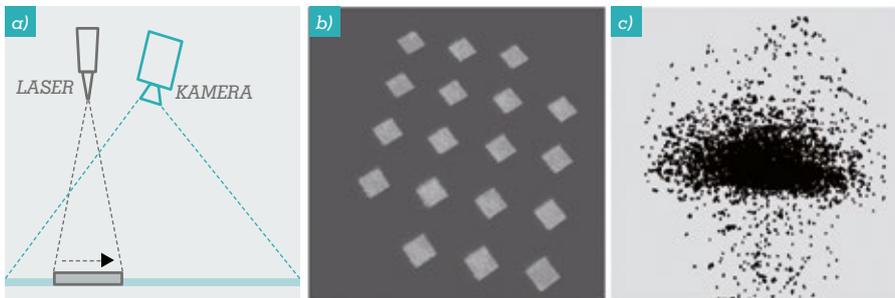


Bild 1: Aufbau OT (a), OT-Schichtbild (b) und 3D-OT-Darstellung eines Bauteils (c)

der Laser. Als weiteren Vorteil ist der günstige Preis der CMOS-Kameras bzw. des optischen Tomografiesystems zu nennen. Durch die Langzeitbelichtung über die gesamte Bearbeitungsdauer einer Schicht wird die thermische Strahlung der aufgeschmolzenen Bereiche der Pulverschicht erfasst und in einem Intensitätsbild (vgl. Bild 1b) mit bis zu 60 Megapixel Auflösung dargestellt. Die Summierung aller Intensitätsbilder der generierten Schichten ergibt das dreidimensionale pyrometrische Abbild der Bauteile (vgl. Bild 1c). Für das Onlinemonitoring des Fertigungsprozesses werden jedoch nur einzelne OT-Schichtaufnahmen verwendet, um ggf. korrektiv in den Bauprozess eingreifen zu können und damit den Ausschuss an Bauteilen zu verringern bzw. zu vermeiden. Neben der Detektion von Prozessabweichungen, wie etwa dem sog. Process Flipping, d. h. dem Schwanken zwischen Wärmeleit- und Tiefschweißen, der Pulverkontamination, die durch Verunreinigungen mit Fremdpartikeln entsteht, dem Pulveraufwurf sowie inhomogener Schutzgasströmung kann bei entsprechender Auflösung auch Versatz, d. h. Abweichungen von der Sollgeometrie der Bauteile, mit der optischen Tomografie detektiert werden.

Darstellung eines Versatzes in der OT

Während mit einem mikroskopischen Verfahren (vgl. Bild 2a) eine definitive Kante eines Versatzes an dem gefertigten Bauteil zugeordnet werden und somit die Breite des Versatzes quantitativ ermittelt werden kann, erlaubt die optische Tomografie keine quantitative Bestimmung der Kante und damit des Versatzes

(vgl. Bild 2b). Das OT-Bild resultiert aus einem Strahlungsbild aufgrund einer energetisch absorbierten Energie, die von einem Laser während des Aufschmelzens des Pulvers emittiert wird. Aus Richtung der Bauteilkante fließt dann ein Wärmestrom in Richtung Pulver, der eine „scharfe Kante“ im OT-Bild verhindert. Sowohl der Wärmefluss als auch andere optische Einflüsse lassen die Kante unscharf erscheinen. Es überlagern sich demnach zwei Effekte: die Verschiebung der Kante in Folge einer Dejustierung des Lasers sowie eine Unschärfe in Folge von Defokussierung durch Wärmefluss. Dies bedeutet: Der OT-Aufnahme ist ohne weitere Datenverarbeitung nur ein Bereich zu entnehmen, in dem sich der Versatz befinden könnte. Unter Berücksichtigung der Auflösung der OT-Kamera und den gegebenen Toleranzen können die Daten der OT ohne weitere Datenbearbeitung bzw. Klassifizierung für den angedachten Einsatzzweck nicht verwendet werden.

Detektion von Kanten

Die klassische Methode, bestimmte Merkmale aus Bildern zu isolieren oder Informationen zu gewinnen, ist die konventionelle Bildverarbeitung. Hierbei muss der Anwender ebenfalls mathematische Operationen an den Bilddaten durchführen, um Kanten, Intensitätswerte oder Zusammenhänge zu isolieren, sichtbar zu machen oder quantitativ zu messen. Allerdings muss jeder Bearbeitungsschritt dabei durch den Anwender explizit vorgegeben werden.

Bei der Detektion von Kanten in Bildern wird meist nach Bereichen mit starken Kontrastunterschieden ge-



sucht. Ein geeigneter und sehr robuster Algorithmus hierfür ist beispielsweise der Canny-Algorithmus, der allerdings zwei Schwellwerte als Eingabe benötigt, die je nach Art des Bildes angepasst werden müssen. Dies zeigt ein grundlegendes Problem: Je nach Vorgehensweise müssen Parameter gewählt werden, um mit entsprechenden Algorithmen von den Rohdaten zu den Resultaten zu gelangen. Abhängig von der subjektiven Wahl der Parameter können die Ergebnisse variieren.

Lösungsansatz mit Künstlicher Intelligenz

Die Idee zum Einsatz der Künstlichen Intelligenz (KI) für dieses Auswerteproblem besteht nun darin, die Kantenschärfe und den Versatz der Kante durch eine Vielzahl von Trainingsbildern in einer KI anzulernen, um später eine Prognose zur Position des Versatzes aus realen Messdaten treffen zu können. Die Trainingsbilder wurden der KI nicht aus realen Daten zur Verfügung gestellt, sondern als synthetische Daten

aus Simulationsdaten, die auf der Sigmoid-Funktion basieren. Hierdurch kann der Umfang der verfügbaren Trainingsdaten beliebig gesteigert werden.

In Bild 2d ist hierzu der mathematische Ansatz dargestellt. Die rote Kurve entspricht dabei dem experimentell ermittelten Kantenverlauf zwischen dem aufgeschmolzenen Bereich und dem benachbarten Pulverbett. Dies entspricht im Bild 2c dem Verlauf von Schwarz nach Weiß. Dieser Verlauf kann nun durch eine Sigmoid-Funktion (weiße Kurve in Bild 2e) angenähert werden.

Um die simulierten Daten der Realität anzugleichen, wird zusätzlich durch einen Zufallszahlengenerator eine Sequenz zufälliger Zahlen generiert und als ein Muster angeordnet, das den realen Messdaten ähnelt. Dieses Zufallsmuster wird der Sigmoid-Funktion überlagert. Durch die Simulation ist es dann möglich, eine große Anzahl von Trainings- und Testdaten zu

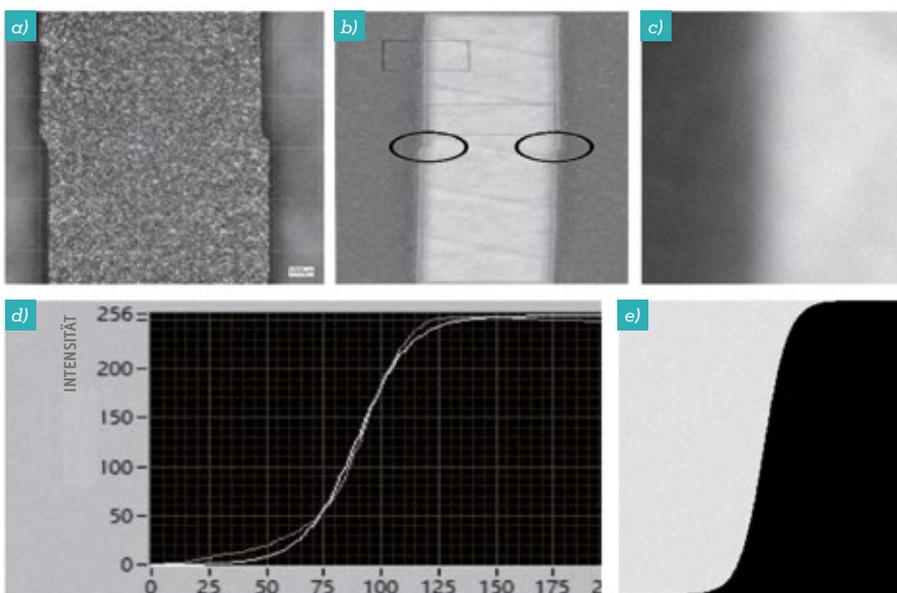


Bild 2: Mikroskopische Aufnahme (a), OT-Aufnahme des Versatzes (b), Zoom-OT-Aufnahme des Versatzes (c), Intensitätsverlauf an der Versatzstelle (d) und Trainingsbild der KI (e)



erzeugen, die dem Transfermodell der KI als Daten zur Verfügung gestellt werden können.

Kombiniert werden dann eine große Anzahl an Positionsveränderungen (Kantenpositionen) in Abhängigkeit von einer großen Anzahl unterschiedlicher Kantenschärfen. Die Daten zur Validierung werden in ähnlicher Konfiguration erstellt. Alle Daten unterscheiden sich hinsichtlich ihrer zufällig überlagerten Strahlungssignaturen, die jenen der realen Daten ähnlich sind.

Aus den so generierten Kurven wird durch Auffüllen oberhalb und unterhalb der Kurve ein Bild der Größe 200 x 200 Pixel mit 8 Bit Tiefe erzeugt (vgl. Bild 2c). Mit allen Variationen wurden insgesamt 3200 Bilder zum Anlernen der KI erzeugt. Außerdem werden 1600 aus realen Baujobs stammende Testbilder zur Evaluierung des KI-Modells erzeugt.

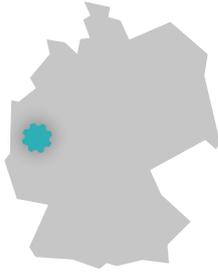
Anlernen und Validieren der KI

Als Modell für die KI wurde ein Transfermodell (ResNet50) gewählt und mit den 3200 generierten Trainingsbildern angelern. Zur Validierung des Scanfeldversatzes wurden geeignete Probengeometrien entwickelt. Die Bestimmung des Versatzes stand beim Design der Probekörper im Fokus. Dabei war zu beachten, dass es zwei unterschiedliche Formen von Versatz gibt. Der erste Versatztyp ist jener innerhalb einer Schicht, beispielsweise durch ungenügende Kalibrierung von Scanfeldern. Der zweite Versatztyp ist jener, der über die Dauer eines Baujobs über viele Schichten hinweg auftreten kann. Dieser Versatztyp kann erst nach der Fertigstellung mehrerer Schichten detektiert werden und ist demnach als Ausschusskriterium für das Bauteil zu verstehen. Typischerweise entsteht dieser Typ durch das allmähliche Aufheizen der Optiken oder auch optomechanischer Komponenten innerhalb des Strahlenganges und der Anlage. Zur Ermittlung dieser beiden Versatztypen wurden jeweils entsprechende Probekörper entworfen und anschließend

in der PBF-LB/M-Anlage hergestellt. Dabei wurden Kantenversätze von 50 bis 200 Mikrometer realisiert. Für die Untersuchung des horizontalen Versatzes wurden in der Ebene liegende Quader mit spezifisch variierendem Versatz konstruiert. Für die vertikalen Versätze wurden stehende Quader konstruiert, die mit anwachsender Zahl an Schichten spezifische Versätze aufweisen.

Anschließend wurde das trainierte künstliche neuronale Netz (KNN) auf die OT-Bilder der Testbauteile angewendet klassifiziert und die berechnete Versatzbreite der realen Versatzbreite gegenübergestellt. Bei dem vertikal auftretenden Versatz wird über die Bauhöhe gemittelt und die relative Abweichung (Versatz) zur ersten Stufe ermittelt.

Hierbei konnte eine Genauigkeit Vorhersagewahrscheinlichkeit von ca. 85,2%, bezogen auf die Übereinstimmung zwischen berechneten und realen Werten der Testdaten, erreicht werden. Das abschließend konvertierte KNN konnte in die OT-Erfassungs- und Analysesoftware unter LabView® implementiert werden und steht nun als zusätzliches Analysetool bei der Nutzung von OT für die Prozessüberwachung des PBF-LB/M-Prozesses zur Verfügung.



MULTIMODALE PROZESS- ÜBERWACHUNG VON PULVERBETTBASIERTEM LASERSTRAHLSCHMELZEN

Dennis Jutkuhn (Fraunhofer-Einrichtung für Additive Produktionstechnologien IAPT), Dieter Weiler (Q2Web GmbH), Frank Weissbuch (ThetaScan GmbH), Arne Erdmann (Raytrix GmbH)

KI-LÖSUNGEN AUS DER PRAXIS / KI-METHODEN

Künstliche Intelligenz kann mithilfe von multimodalen Datenquellen eine frühzeitige Qualitätskontrolle zur Defekterkennung von im Druckprozess befindlichen Bauteilen in der pulverbettbasierten additiven Fertigung ermöglichen. Am Beispiel einer prototypischen In-situ-Multisensorüberwachung wird gezeigt, wie ein solches multimetrischen Prozessabbild aufgebaut und mittels KI ausgewertet werden kann. (siehe Abbildung 1.)

Die Etablierung von pulverbettbasierten additiven Fertigungsverfahren in der Industrie steht vor der Herausforderung einer effektiven prozessbegleitenden Qualitätskontrolle. Diese Qualitätskontrolle muss frühzeitig, also bereits während des Produktionsprozesses, aussagekräftige Informationen zur Integrität und Qualität der gefertigten Bauteile liefern. Die aktuelle Problematik liegt in den begrenzten Möglichkeiten der In-situ-Qualitätsüberwachung, der echtzeitfähigen Handhabung und Verarbeitung der großen generierten Datenmengen und der fehlenden Analyse dieser Daten zur Identifikation und Klassifikation von Fehlern im laufenden Prozessgeschehen sowie im gefertigten Bauteil. Der industriell relevanteste additive Fertigungsprozess des selektiven Laserstrahlschmelzens für Metalle (Laser Powder Bed Fusion for Metal, PBF-LB/M) bietet technologisch gesehen

die Möglichkeit, den Materialauftrag entlang der aufeinanderfolgenden Schmelzspuren und Schichten zu einem dreidimensionalen Bauteil zu überwachen. Beim PBF-LB/M-Prozess handelt es sich allerdings um einen der komplexesten Produktionsprozesse, bei dem schon kleine Veränderungen innerhalb der relevanten Parameter zu erheblichen Defekten oder Abweichungen innerhalb der generierten Produkte führen können. Grundsätzliche Parameter des Bauprozesses, wie Pulverqualität und der Pulverpartikelgröße und -form, der Verteilung der Partikelgrößen innerhalb des Gemenges, die Materialqualität und enthaltene Verunreinigungen, Maschinenparameter wie Laserleistung, Laser-Scan-Geschwindigkeit, Hatchabstände, Schichtauftragsgeschwindigkeit des Pulvers, Qualität des Inertgases und die Geschwindigkeit der Prozessgasströmung, beeinflussen auf direkte Weise die resultierende Produktqualität. Schon kritische Veränderungen in nur einer einzelnen Schicht, zum Beispiel durch Temperaturakkumulation oder Spritzerbildung, können eine fortlaufende Minderung der Qualität aller nachfolgenden Schichten verursachen. Andersherum kann die erneute Aufschmelzung des bereits gefügten Materials bei Erzeugung einer Folgeschicht zu nachträglichen Defekten in den vorherigen Schichten führen. Bei Bauteilen, die aufgrund ihrer Verwendung zertifiziert werden müssen, ergibt sich hierdurch, dass im aktuellen Stand der Technik durch einen aufwendigen Prozess für exakt eine Fertigungs-



anlage der entsprechende Baujob eingerichtet und eingemessen werden muss. Es werden Prüfkörper im Bauprozess mitlaufend gefertigt, von denen anschließend durch nachgelagerte Prüfungen Rückschlüsse auf die Produktqualität erwartet werden. Allerdings gibt es bisher keine zuverlässige Einzelmethode zur In-situ-Prozessüberwachung und Dateninterpretation, die eine Korrelation zwischen Prozessdaten und prioritären Bauteildefekten mit einer hohen Wiederholwahrscheinlichkeit der Detektion (Probability of Detection, POD) erfolgreich herstellen konnte. Bislang war kein Ansatz in dieser Richtung erfolgreich, weder hinsichtlich der eingesetzten Überwachungsverfahren noch durch Einsatz von KI. Es scheiterte bislang an der Korrelation der Prozessdaten zu den Defekten. Fusionierung, Verarbeitung und Auswertung der Daten müssten in unter 0,3 sec. erfolgen, um für die nachfolgende Schicht nutzbar zu sein. Dies ist aktuell prozessparallel aufgrund der Datenmengen nicht möglich. Welche Prozessdaten dafür relevant sind, ist bislang unbekannt. Daher ist der multimodale Ansatz verschiedener Prüftechniken notwendig, um diesen Zusammenhang zwischen Prozessdaten und Defekten herauszufinden. Die bisherigen Ansätze bleiben hinter den Möglichkeiten zurück und bieten allenfalls eine Indikation für die Qualität. Daher kann die Qualität der Bauteile im eigentlichen Sinne bislang erst nach Abschluss des Druckprozesses hinsichtlich Integrität, Materialdichte, Formtreue und Oberflächengüte überprüft werden. Die oftmals hohe Varianz in der Bauteilqualität dieses hochkomplexen Fertigungsverfahrens führt zu einem hohen Anteil an Produktionsausschuss sowie an aufwändigen und sich wiederholenden Iterationen zum Einfahren des bauteilabhängigen Prozesses und erfordert kostenintensive nachgelagerte Qualitätsprüfungen. Der im Projekt verfolgte Ansatz, eine aussagekräftige indirekte Detektion von Defekten und die Validierung der Bauteilqualität während des

Druckprozesses auf Basis einer multimodalen Prozessüberwachung, deren fusionierte Prozessdaten mittels KI echtzeitfähig analysiert und ausgewertet werden, verspricht dieses Problem zu lösen, den Kosten- und Zeitaufwand signifikant zu verringern sowie nachgelagerte Qualitätssicherungsschritte einzusparen. Eine solche In-situ-Qualitätskontrolle eröffnet zudem die Option für eine adaptive Prozessregelung, die die Prozessstabilität erhöht und frühzeitige Prozessabbrüche ermöglicht, um zukünftig Ausschuss zu minimieren und ressourceneffizienter zu produzieren.

Aufbau eines multisensorischen In-situ-Prüfsystems für den PBF-LB/M-Prozess

Der Stand der Technik umfasst bereits diverse In-Situ-Prüfverfahren für den PBF-LB/M-Prozess, wie zum Beispiel 2D- und 3D-Kameralösungen zur Überwachung der Baupläche, Ultraschallsensorik und die Erfassung der thermischen Schmelzbaddynamik. Diese Verfahren liefern für sich allein jedoch keine ausreichenden Informationen über die Lage, Form und Konzentration von prioritären Defekten wie Poren, Rissen, Lunkern und Schichtenbindungsfehlern. Im Projekt SenseAI wurde das Ziel verfolgt, ein sich durch unterschiedliche Prüfprinzipien sinnvoll ergänzendes multimodales In-situ-Prüfsystem prototypisch zu entwickeln und aufzubauen. Diese Multisensorik beinhaltet die Erfassung der thermischen Prozesssignatur des Schmelzbads (Melt Pool Monitoring, MPM), der zeitabhängigen Temperaturentwicklung mittels optischer Thermografie (Online-Diagnose-Tool, ODT), die permanente 3D-Topografieüberwachung der Pulverschicht und des Bauteils mittels Lichtfeldtechnologie (Light Field Imaging, LFI) sowie die Aufnahme von Maschinendaten und Peripherieinformationen. Bei der Entwicklung wurde die optische Tomografie des additiven Baufelds durch die Verwendung von Astro-Kameras



mit Auflösungen größer 60 Megapixel sowie der Verwendung von Mehrkanal-RGB-Daten auf ein neuartiges Level hinsichtlich Auflösung und multispektraler Auswertung gebracht. Das innovative Prinzip der Lichtfeldtechnologie, das sowohl 2D- als auch 3D-Informationen einer Szene in einer Aufnahme erfasst, wurde als besonders vielversprechend für die Echtzeitüberwachung von Hochgeschwindigkeitsprozessen wie dem PBF-LB/M-Prozess betrachtet. Die Raytrix GmbH hat die Multi-Focus-Plenoptic-2.0-Lichtfeldtechnologie entwickelt und patentiert, die eine höhere Auflösung und erweiterte Tiefenschärfe ermöglicht. Integriert wurde die Multisensorik in eine industrielle PBF-LB/M-Anlage am Fraunhofer IAPT in Hamburg, um die vielseitigen qualitätsrelevanten Prozessmerkmale simultan zu erfassen und zu überwachen.

Multimodale Datenfusion zum Aufbau eines räumlich und zeitlich synchronisierten Prozessabbilds als digitaler Zwilling

Die generierten Daten aus einer Vielzahl an Fertigungszyklen, bei denen neben der Variierung von Prozessparametern, wie zum Beispiel der Laserleistung, auch künstliche Fehlstellen in Probekörper induziert wurden, bilden die Grundlage für die Anlernung der Künstlichen Intelligenz. Für die automatisierte Vorhersage von Bauteildefekten mittels KI wurde eine

Datenbankstruktur entwickelt, in der die im Prozess generierten multimodalen Messdaten gespeichert und strukturiert abgelegt werden. Eine Datenfusion zur räumlichen und zeitlichen Synchronisation der Prozessdaten in einem einheitlichen Datenraum mit Referenzkoordinatensystem, die für ein tiefgründiges Prozessverständnis und eine Korrelation zu physischen Prozessanomalien und Bauteildefekten zwingend erforderlich ist, ermöglicht eine physikalisch sinnvolle Interpretation der Daten in Bezug auf das Prozessgeschehen sowie die Erstellung eines ganzheitlichen 3D-Prozessabbilds (siehe Abbildung 2). Eine Korrelation zu physischen Defekten kann nur erfolgen, sofern die räumliche und zeitliche Zuordnung der Daten während der prozessbegleitenden Datenakquise bei der Fusionierung und Interpretation der Daten berücksichtigt wird. Auf dieser Grundlage wurde ein KI-basiertes Datenanalysetool entwickelt und trainiert, das die automatische Detektion, Identifikation und Klassifizierung von Defekten ermöglicht. Für die Anlernung und Validierung der Performance der KI wurden im Anschluss an die Fertigung die gefertigten Probekörper mittels etablierter Prüfmethode geprüft, wie z. B. der Computertomografie und der Erzeugung von Schlibfbildern, um die physische Ausprägung von den Fehlstellen zu erfassen.

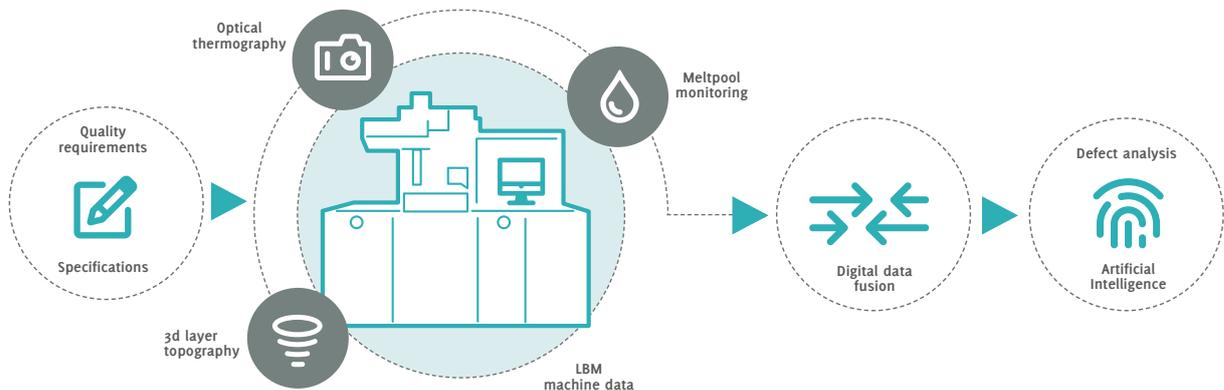


Abbildung 1: Aufbau des ProLern-Projektes SenseAI

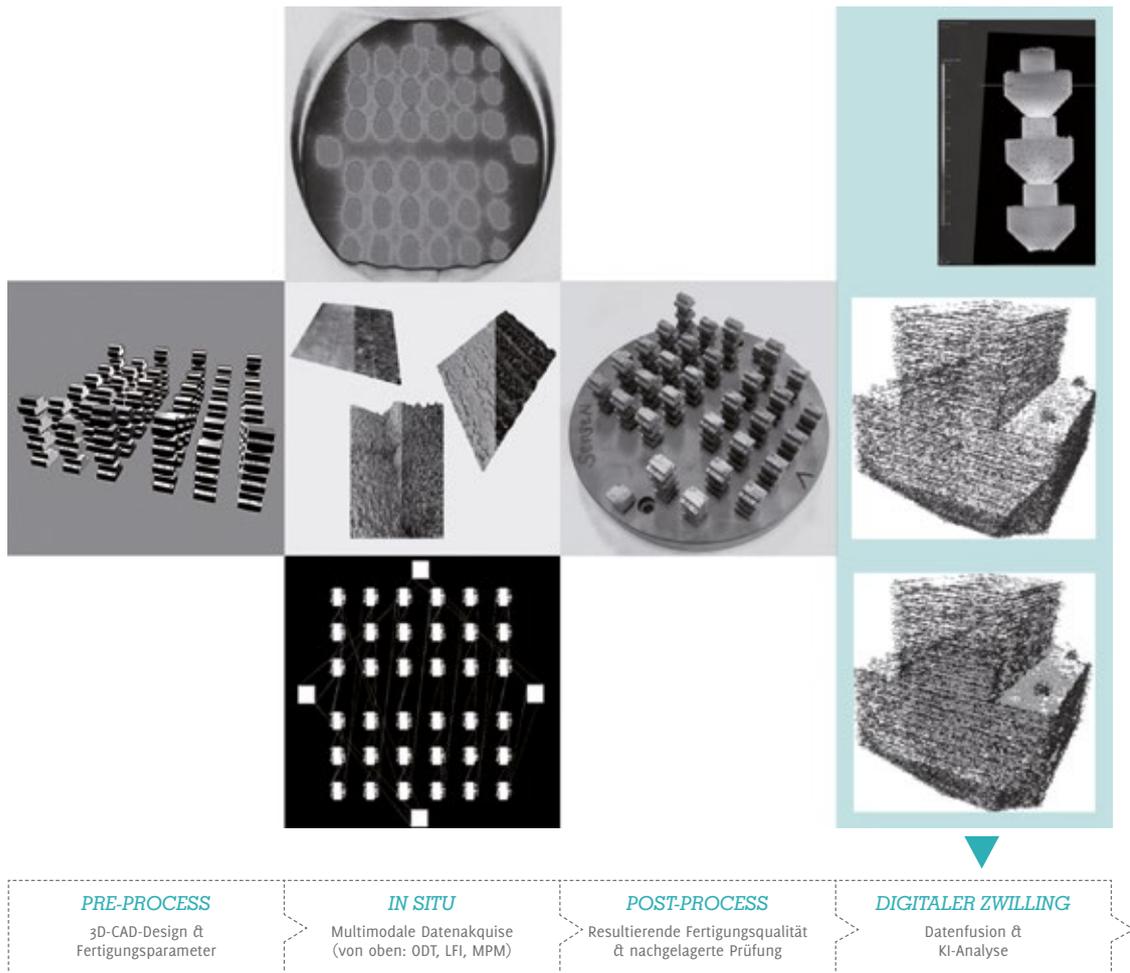


Abbildung 2: Darstellung multimodaler und synchronisierter Daten des 3D-Druckprozesses als 3D-Prozessabbild (digitaler Zwilling)

Entwicklungsansätze einer Überwachungs- und Defekterkennungs-KI für die prozessbegleitende Qualitätskontrolle im PBF-LB/M-Prozess

Die KI-gestützte Untersuchung von PBF-LB/M-Bauteilen ist bereits Stand der Technik. Es werden dreidimensionale Dichteabbilder mittels CT-Technologie erstellt und Bereiche geringerer Dichte werden als Defekte identifiziert. Diese können per KI lokalisiert, aber nicht zuverlässig klassifiziert werden. Um die kostenintensiven CT-Untersuchungen zu vermeiden, wurde an datengestützten In-situ-Lösungen zur Defektvorhersage geforscht. Diese Ansätze nutzen CT-Daten als Anlernbasis und In-situ-Prozessdaten eines Sensors als Eingabedaten. Für die automatische Defekterkennung wurden Convolutional Neural Networks (CNN) als Teilgebiet des Deep Learning als überlegener Ansatz im Vergleich zu herkömmlichen Analysealgorithmen für das automatische Labeling der Defekte aus den CT-Daten verwendet. Die gesteigerte

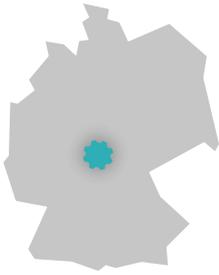
Leistungsfähigkeit von GPUs und Algorithmen ermöglicht die Verarbeitung großer Datensätze durch CNNs. Diese Netzwerke haben ihre Dominanz in der visuellen Klassifizierung und Regression vielfach bewiesen. Weitergehend wurden diese Daten genutzt, um, basierend auf und kombiniert mit den Sensor Daten, ein entsprechendes Defekterkennungsmodell zu trainieren.

Damit ein In-situ-Prüfsystem für die Prozessqualifizierung vollständig genutzt werden kann, muss die kausale Korrelation zwischen In-situ-Prozessdaten und physischen Bauteildefekten hergestellt werden. Dies ist eine große Herausforderung und erfordert einen erheblichen Aufwand für die Entwicklung neuer Repräsentationsmodelle für die Speicherung komplexer physikalischer Abhängigkeiten und Beziehungen, der Integration von datengesteuerten Algorithmen mit physikbasierten Modellen sowie umfangreichen Tests. Mittels zerstörungsfreier Prüfung (Mikroröntgentomografie, Dichtebestimmung nach Archimedes-Prinzip)



des eigentlichen Produkts und zerstörender Prüfung (Schliffbilder, Mikroskopie, EDX, Zugversuche) der miterstellten Prüfkörper wird die resultierende Qualität des Bauteils abgeleitet. Alle diese Anforderungen führen zu einem modularen Aufbau der Systemarchitektur, sowohl für die konkret implementierte Produktionsmaschine und deren Sensortechnologien als auch für die Struktur des digitalen Zwillings und der gesamten Software- und Hardware-Architektur, der flexiblen und adaptiven Datenspeicherung und der Integration der unterschiedlichen Sensorformate unter der Berücksichtigung der verschiedenen räumlichen und auch zeitlichen Auflösungen (siehe Abbildung 2). Schlussendlich führte die Messung und Analyse des eigentlichen Baujobs mit möglichst vielen unabhängigen und sich ergänzenden Parametern vor, während und nach der Belichtung jeder einzelnen Schicht zu einem Datenvolumen von ca. 1TB Daten für einen einzelnen Baujob. Diese Prozessdaten wurden um die Daten aus nachgelagerten Prüfungen, in der Regel mittels \leftrightarrow CT, ergänzt, sodass ein dreidimensionales Dichteabbild erzeugt wurde, das durch Schliffbilder zur Ermittlung von charakteristischen Fehlstellen wie Poren, Rissen und Delaminierungen ergänzt wurde. Die Datenspeicherung erfolgte durch die Wahl eines internen Datenmodells, das in der Lage ist, auch in Zukunft neue oder aktuell nicht genutzte Sensortechniken, wie z. B. akustische oder elektromagnetische Prüfverfahren, leicht in den Gesamtprozess integrieren zu können. Spezielle Anforderungen stellen hierbei die Verarbeitung und Speicherung von Sensordaten mit unterschiedlicher Granularität und Auflösung über die Größen Raum und Zeit dar. Da alle Sensordaten in einem jeweils für ihre Anforderungen spezifischen und optimierten Format vorlagen (STL, TIFF, HDF5 oder Point-Cloud), wurden mithilfe von Künstlicher Intelligenz, insbesondere mithilfe von Verfahren zur Bildverarbeitung, die Daten vereinheitlicht und exakt in einem gemeinsamen Koordinatensystem sowohl räumlich als auch zeitlich kalibriert und gemeinsam abgespeichert. Pro Datenpunkt, in der Summe ca. 10 Mrd. pro Baujob, wurden bis zu 40 un-

terschiedliche Attribute ermittelt. Das Annotieren und Labeln der Daten erfolgte, basierend auf den Prozessdaten, sowohl anhand von \leftrightarrow CT als auch anhand von Schnittbildern, mithilfe von optimierten statistischen Verfahren und KI-Algorithmen der Bildverarbeitung. Die gesamte Software-Architektur wurde daraufhin optimiert, dass der digitale Zwilling auf Basis der erzeugten Prozessdaten quasi in Echtzeit alle notwendigen Verarbeitungsschritte durchführen kann. Auf die Daten wurden in einem ersten Schritt KI-Algorithmen angewendet, die pro Bauteil und Schicht eine Beziehung zwischen Attribut-Vektor und annotierten Daten generierten. Hieraus ergaben sich durchschnittliche Erkennungsquoten im üblichen Rahmen von ca. 85%. Die Kombination von Sensor- und Qualitätsdaten für das Trainieren eines Erkennungsmodells ermöglicht es, bei nachfolgenden Baujobs Aussagen bezüglich der Defekte und der Defekthäufigkeit ausschließlich auf Grundlage der Sensordaten, ohne die Notwendigkeit von CT-Daten, treffen zu können. Durch die exakte Kalibrierung der Datenpunkte ist es nun auch möglich, Algorithmen zu entwickeln und anzuwenden, welche die Topologie der Bauteile auch auf jeweils kleinere Ausschnitte reduziert und diese insbesondere auch im Dreidimensionalen betrachtet. Hier gehen wir von einer deutlich erhöhten Erkennungsquote und vor allem exakten Lokalisierung von Defekten innerhalb der Bauteile, abhängig von der Topologie, aus, die sich aktuell in der Validierung befindet. Aufgrund der erzielten Ergebnisse sehen wir in den realisierten Projektergebnissen die Möglichkeit, standardisierte Datensätze mit hoher Qualität und Zuverlässigkeit zu generieren, die den PBF-LB/M-Produktionsprozess räumlich und zeitlich vollständig abbilden. Durch die Verwendung der durch eine Reihe von Baujobs ermittelten Rohdaten unterschiedlicher Auflösung und unterschiedlicher Bauparameter besteht erstmalig die Möglichkeit zum Aufbau eines qualitätsgesicherten, validierten und annotierten multimodalen Datenpools, der mittels KI analysiert und für einen Rückschluss auf die vorherrschende Fertigungsqualität genutzt werden kann.



pAIInt-Behaviour

RÜCKVERFOLGBARE ANOMALIE-DETEKTION IN LACKIERANLAGEN MITTELS UNÜBERWACHTEM TRANSFER LEARNING

Jonas Gram (Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA)

Durch den Einsatz von unüberwachtem Transfer Learning können Anomalien in Lackieranlagen frühzeitig erkannt und somit Verursacher von Produktfehlern effizient identifiziert werden.

Qualitätssicherung ist in der modernen Fertigungstechnik essenziell, insbesondere in der hochautomatisierten Kunststofflackierung der Automobilindustrie. Aufgrund von hohen Produktvolumen und Automatisierungsgraden können Prozessabweichungen zu erheblichen Qualitätsmängeln führen, die oft erst am Ende der Produktionslinie in der Qualitätskontrolle identifiziert werden. Unser Ansatz nutzt unüberwachtes Transfer Learning, um Anomalien im Produktionsprozess frühzeitig zu erkennen und so mögliche Ursachen von Fehlern zu identifizieren, bevor diese zu gravierenden Qualitätsproblemen führen.

Problemstellung

Die Anwendung von Künstlicher Intelligenz (KI) und maschinellem Lernen (ML) hat in zahlreichen Disziplinen bedeutende Fortschritte erzielt; dennoch befindet sich die Produktionstechnik noch in einer frühen Phase dieser Entwicklung ^[1]. Insbesondere bei der Lackierung von Automobilteilen ist die Prozesskette trotz hoher Automatisierung und sensorischer Überwachung nicht vollständig beherrschbar. Aufgrund der hohen Stückzahlen sowie der wertvollen Werkstoffe

und Komponenten verursachen Qualitätsmängel hohe Kosten und verringern die Liefertreue durch Nacharbeiten oder einen reduzierten Produktionsoutput. Es ist essenziell, frühzeitig Prozessabweichungen zu identifizieren und so mögliche Ursachen von Fehlern zu lokalisieren. Hauptursachen für Ausschuss und Nacharbeit sind unter anderem Staubeinschlüsse und Schichtdickenabweichungen. Es fehlt an physischen Beschreibungsmodellen und der Fähigkeit, multikausale Wechselwirkungen der Sensoren und Aktoren des komplexen Lackierprozesses zu beherrschen. Hier setzt unser Projekt „pAIInt-Behaviour“ an, um die kognitive Aufgabe zu übernehmen, den Prozessablauf auf kritische Pfade und Tätigkeiten zu analysieren, kontinuierlich zu überwachen und somit den Ausschuss zu reduzieren.

Zielsetzungen

1. Identifikation kritischer Komponenten und Messwerte anhand historischer Analysen zur Optimierung des Prozesses
2. Automatisierte Zuweisung des Prozessverhaltens auf Sensorebene zur Qualitätssicherung
3. Kontinuierliche Überwachung des Lackier-Produktionsprozesses anhand von Sensordaten und frühzeitige Meldung potenzieller Fehlerquellen

Diese Primärziele dienen der Vermeidung von Qualitätsmängeln und der Steigerung der Effizienz.



Abstraktion

Aufgrund des hohen Automatisierungsgrads und der großen Anzahl an Sensoren ist die manuelle oder regelbasierte Prozessüberwachung nur durch kostenintensive Beratung mit Prozessexperten möglich. Die komplexen Wechselwirkungen innerhalb des Lackierprozesses zwischen Materialeigenschaften, Prozessen, Umgebungsbedingungen und Messsystemen verhindern die Effektivität und Einsatzmöglichkeiten regelbasierter Qualitätsüberwachungen ^[2].

Um diesen Herausforderungen zu begegnen, wird ein datenbasierter und unüberwachter Ansatz angestrebt. „Unüberwacht“ bedeutet in diesem Kontext, dass die Daten vorher weder markiert noch klassifiziert wurden, was den Vorteil bietet, dass vorhandene Daten des Automatisierungssystems direkt evaluiert werden können ^[3]. Diese umfassen beispielsweise Sensordaten der Roboter, Positionssensoren, Signale von speicherprogrammierbaren Steuerungen (SPS), Qualitätsdaten oder Messdaten, um die Lackierung besser zu überwachen.

Diese Daten werden während der Lackierung generiert und sind im Zeitverlauf den zu lackierenden Bauteilen zugeordnet. Diese Bauteile werden gruppiert als sog. Skid, einem Gebinde bestehend aus vier Teilen, verarbeitet. Das System generiert somit hochdimensionale numerische und binäre Zeitreihendaten, was den Erfolg unüberwachter datenbasierter Analysen begünstigt. Da ein isoliertes Auswertemodell den Anforderungen eines hochautomatisierten Produktionssystems mit großen Datenmengen und komplexen Wechselwirkungen nicht genügt, haben wir ein Set aus mehreren Deep-Learning-Modellen aufgebaut.

Vorgehen

Im ersten Schritt werden die wichtigsten Prozess- und Qualitätsparameter ausgewählt. Hierbei handelt es sich um die entscheidenden Sensordaten, die für die Überwachung und Optimierung des Lackierprozesses

relevant sind. Diese Daten umfassen hochdimensionale Zeitreihendaten, die sorgfältig vorverarbeitet werden müssen, um für die Modellbildung geeignet zu sein.

Anschließend wird ein Modell für die Anomalie-Detektion ausgewählt und parametrisiert. Diese Architektur basiert auf Daten ähnlicher Problemstellungen, Laboraufbauten oder allgemein vergleichbarer Datenstrukturen. Für die Modellbildung werden verschiedene neuronale Netze mit unterschiedlichen Stärken in eine Autoencoder-Architektur integriert. Dabei kommt Transfer Learning zum Einsatz, um die Modellarchitektur initial zu parametrisieren und die Hyperparameter entsprechend anzupassen.

Das Modell wird dann auf Basis der Daten der Lackieranlage trainiert und final parametrisiert. Nachdem das Modell das Normalverhalten des beobachteten Lackierprozesses gelernt hat, wird es zur Online-Anomalie-Detektion eingesetzt. Dies ermöglicht eine kontinuierliche Überwachung des Lackierprozesses und die frühzeitige Meldung potenzieller Fehlerquellen.

Ergänzend erfolgt eine historische Prozessanalyse, um kritische Komponenten und Messwerte zu lokalisieren. Durch die automatisierte Zuweisung des Prozessverhaltens auf Sensorebene wird eine umfassende Qualitätssicherung erreicht.

Das Vorgehen ist in der Prinzipskizze der Abbildung 1 grafisch zusammengefasst.

Datenvorverarbeitung

Zunächst wird in Zusammenarbeit mit Lackier- und Anlagenexperten entschieden, welche Sensoren und Datenvariablen für den Prozess und die Qualitätsüberwachung von entscheidender Bedeutung sind. Diese umfassen mehrere Gruppen von Signalen. Insbesondere werden wichtige Messsensoren an den Lackierrobotern berücksichtigt, die beispielsweise den Luftdruck, den Pumpendruck, den Luftvolumenstrom und den Lackvolumenstrom überwachen. Ergänzend werden weitere Messdaten pro Bauteil erfasst, wie die

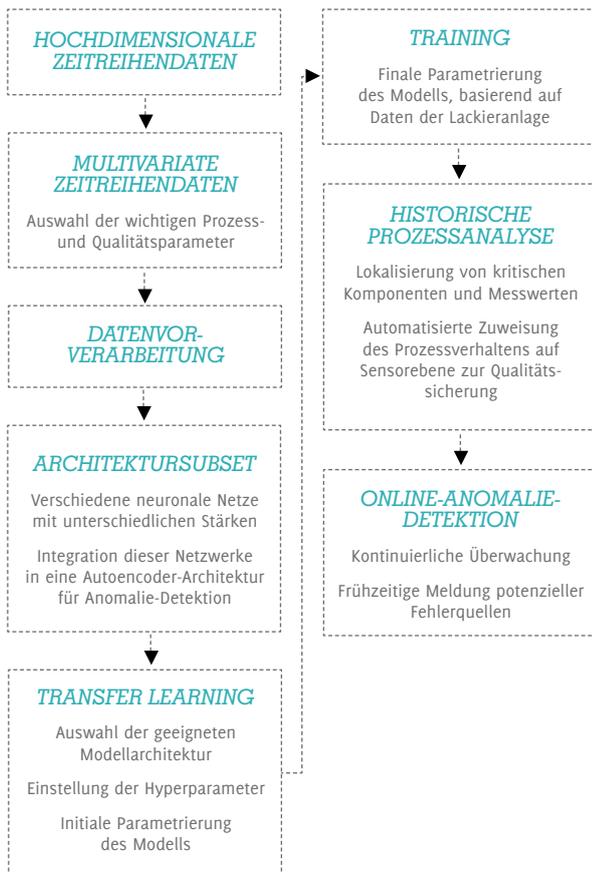


Abbildung 1: Prinzipialskizze des Projekts: von den Daten der Lackieranlage bis zu den Ergebnissen der Modellierung

Farbmetrikmessung oder die Schichtdicke des Lacks. Zur vollständigen Modellierung des Prozessverhaltens werden zudem binäre Prozess- und Positionssignale betrachtet, die Informationen über Starts und Stopps von Teilarbeitsschritten liefern. Im Falle von Unklarheiten werden bevorzugt mehr Signale als nötig betrachtet, um sicherzustellen, dass keine Signale mit essenziellen Verhaltensmustern ausgeschlossen werden.

Anschließend werden für die Primärziele 1 und 2 historische Daten aufgebaut und nach Zeitstempel und Skid verknüpft, um eine eindeutige Zuweisung und Rückverfolgbarkeit von anomalem Verhalten zu ermöglichen. Für das Ziel 3 der Prozessüberwachung wird ein Edge Device an die OPC-UA-Schnittstelle der prozesssteuernden SPS sowie an das Qualitätsmanagementsystem angebunden.

Um eine detailreiche Untersuchung der Wechselwirkungen zwischen den Komponenten der Lackierproduktion über den Zeitverlauf und zwischen den

Signalen zu gewährleisten, haben wir die Sliding-Window-Methode angewendet. Diese gleitet kontinuierlich über das Datenmaterial und betrachtet kleine, überlappende Segmente. Dadurch können zeitliche Veränderungen und Korrelationen präzise erfasst werden^[4]. Die Datenverarbeitung wurde in Python mithilfe der Bibliothek Numpy^[5] umgesetzt.

Architektur

Basierend auf der ermittelten Datenstruktur des beobachteten Lackierprozess und den damit einhergehenden Anforderungen wählen wir ein Set von Anomalie-Detektions-Modellen aus. Die folgenden Modellarchitekturen werden berücksichtigt:

- 1. Autoencoder (AE):** Autoencoder sind neuronale Netzwerke, die darauf trainiert werden, Daten in eine niedrigdimensionale Form zu komprimieren und diese anschließend wieder zu rekonstruieren. Durch das Training auf Prozessdaten lernen Autoencoder typische Muster zu repräsentieren. Wenn sie auf Anomalien angewendet werden, erzeugen diese größere Rekonstruktionsfehler, da sie von den gelernten normalen Mustern abweichen^[6]. Diese Eigenschaft macht Autoencoder besonders geeignet für die Anomalie-Erkennung. Laut einer Studie von Sakurada und Yairi^[7] ist die Anomalie-Erkennung mit Autoencodern besonders effektiv in der Erkennung von Abweichungen in hochdimensionalen Daten.
- 2. Graph Attention Network (GAT) - Autoencoder:** GAT^[8] eignen sich für die Modellierung und Analyse von Daten, die viele Wechselwirkungen und Interkorrelationen aufweisen. Das GAT modelliert eine neue graphenbasierte Datenstruktur, in der diese stärker hervortreten. Basierend auf dieser neuen Datenstruktur wird Anomalie-Detektion durch einen Graph-AE ermöglicht.
- 3. Transformer Autoencoder:** Verwendung von Transformern zur Modellierung und Erkennung von komplexen Anomalien in zeitlichen Daten. Durch das Self-Attention-Prinzip können Kontextinfor-



mationen über gesamte Sequenzen berücksichtigt werden. Durch die Modellierung der Interaktionen der Variablen werden zudem Wechselwirkungen stark berücksichtigt ^[9].

Transfer Learning

Da die Verhaltensmodellierung und Anomalie-Detektion unüberwacht erfolgt, ist es nicht trivial, die ideale Modellarchitektur inklusive der vielen weiteren Einstellungsparameter (Hyperparameter) festzulegen. Deshalb nutzen wir die Technik des Transfer Learnings ^[10], um Wissen von ähnlichen Datenstrukturen und Problemen einfließen zu lassen. Zunächst wurden Datensätze aus bereits analysierten Produktionsanlagen, Laboraufbauten und Open-source Daten, die eine vergleichbare Datenstruktur und Anwendungsfall aufweisen, gesammelt.

Nun wird zunächst das Set der Modelle in PyTorch implementiert ^[11]. Mittels der Python-Bibliothek Optuna ^[12] wird die ideale Modellarchitektur, basierend auf ähnlichen Anwendungsfällen, ermittelt. Hier sind einige der wichtigsten Hyperparameter, die optimiert werden:

- **Lernrate:** Bestimmt die Schrittweite beim Aktualisieren der Modellparameter
- **Batch Size:** Anzahl der Zeitwerte, die in einem Durchgang durch das Modell verarbeitet werden
- **Anzahl der Modellschichten:** Einstellbarkeit der Komplexität des Modells durch die Vervielfältigung oder Reduzierung der Rechenoperationen
- **Anzahl der Neuronen pro Schicht:** Parametrierung der Datendimensionalität während der Verarbeitung
- **Latente Dimension der Autoencoder:** Dimension, auf welche die Daten komprimiert werden

Nach der Auswahl der geeigneten Modellarchitektur und der Einstellung der Hyperparameter wird das Modell zunächst basierend auf den ähnlichen, bereits

vorhandenen Daten vortrainiert. Dies hilft, eine initiale Parameterkonfiguration der Modellgewichte zu erhalten, die ähnliche Probleme lösen kann und nicht zufällig initialisiert ist, um eine Konsistenz der Problemlösung zu gewährleisten.

Jetzt werden die ausgewählten Daten aus der Datenvorverarbeitung genutzt, um das Modell korrekt auf den Prozess der beobachteten Lackieranlage einzustellen und somit die Verhaltensmodellierung aufzubauen. Unter Annahme des Prozesswissens, dass die überwiegende Anzahl an Bauteilen fehlerfrei lackiert wird, kann das Modell das Normalverhalten des Lackierprozesses in das Verhaltensmodell einarbeiten. Bei der späteren Anomalie-Detektion werden Diskrepanzen gegenüber diesem erlernten Verhaltensmodell als Anomalien gekennzeichnet, die zu fehlerbehafteten Bauteilen führen können. Daten aus der Qualitätskontrolle, ebenso wie zusätzliche Daten von Qualitätsüberwachungssensoren des Prozesses ermöglichen es dem Modell, eine direkte Beziehung zwischen Prozessdaten und der Qualität zu erlernen.

Anomalie-Detektion

Das parametrisierte und personalisierte Verhaltensmodell in Form einer Autoencoder-Variante kann jetzt genutzt werden, um die Primärziele dieser Arbeit zu erreichen. Aufgrund des Aufbaus der Datenstrukturen und des Modells kann ein Anomaliewert für jeden Zeitstempel und jedes Signal, und somit auch für jeden Skid von Produkten, zugewiesen werden. Basierend auf Qualitätsmetriken wie dem durchschnittlichen Ausschuss, Defects per Million Opportunities (DPMO) oder dem Process Capability Index (CPK) erfolgt eine Zuweisung, welche Anomaliewerte kritisch sind und somit auf Prozessfehler hinweisen. Der durchschnittliche Ausschuss gibt an, wie viele fehlerhafte Produkte im Durchschnitt produziert werden ^[13]. DPMO misst die Anzahl der Fehler pro eine Million Gelegenheiten, wobei jede Gelegenheit eine Möglichkeit für einen Fehler darstellt. Der CPK zeigt, wie fähig ein Prozess ist, Produkte innerhalb der Spezifikationsgrenzen zu



produzieren. Anhand dieser Metriken kann festgelegt werden, bei welchen Anomaliewerten ein Eingreifen notwendig ist, um die Qualität der Lackierung sicherzustellen [14].

Fazit

Durch den Einsatz von Autoencoder-basierter Anomalie-Detektion kann die Qualitätssicherung in Lackieranlagen effizient und robust gestaltet werden. Zuerst wurde eine Datenstruktur mit wichtigen Signalen erstellt, basierend auf dem Verständnis des Prozesses. Mit Transfer Learning wird ein passendes Verhaltensmodell vorab trainiert, basierend auf ähnlichen Strukturen und Anwendungen. Dies ermöglicht eine unüberwachte Modellierung ohne großen Aufwand und Kosten für die Experten und Ingenieure. Nach der endgültigen Anpassung und dem Training mit Prozess-, Sensor- und Steuerungsdaten entsteht ein datenbasiertes Verhaltensmodell. Dieses kann in der Trainingsphase mittels Qualitätsdaten weiter dazu optimiert werden, aus dem Prozessverhalten auf die Qualität schließen zu können.

Diese Lösung ermöglicht eine deutliche Verbesserung der Prozessqualität und -effizienz. Kritische Komponenten und Messwerte können durch historische Analysen identifiziert werden, was zu einer gezielten Prozessoptimierung führt. Durch die direkte Integration des Modells in die Lackieranlage wird eine kontinuierliche Überwachung des Lackier-Produktionsprozesses gewährleistet. Dies erlaubt die frühzeitige Erkennung und Meldung potenzieller Fehlerquellen, wodurch die Qualität der Endprodukte erhöht und Ausschuss reduziert wird.

Literatur

- [1] Rom, M., Brockmann, M., Herty, M., Iacomini, E., 2022. Machine learning tools in production engineering. *Int J Adv Manuf Technol* 121 (7-8), 4793-4804.
- [2] Niggemann, O., Maier, A., Vodencarevic, A., Jantscher, B., 2011. Fighting the Modeling Bottleneck - Learning Models for Production Plants.
- [3] Hinton, G., Sejnowski, T.J., 1999. *Unsupervised Learning*. The MIT Press.
- [4] Braverman, V., 2016. Sliding Window Algorithms, in: Kao, M.-Y. (Ed.), *Encyclopedia of Algorithms*. Springer New York, New York, NY, pp. 2006-2011.
- [5] Harris, C.R., Millman, K.J., van der Walt, S.J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N.J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M.H., Brett, M., Haldane, A., Del Río, J.F., Wiebe, M., Peterson, P., Gérard-Marchant, P., Sheppard, K., Reddy, T., Weckesser, W., Abbasi, H., Gohlke, C., Oliphant, T.E., 2020. Array programming with NumPy. *Nature* 585 (7825), 357-362.
- [6] Rumelhart, D.E., McClelland, J.L. Learning Internal Representations by Error Propagation, in: *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations*, pp. 318-362.
- [7] Sakurada, M., Yairi, T., 2014. Anomaly Detection Using Autoencoders with Nonlinear Dimensionality Reduction, in: *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis. MLSDA'14: Machine Learning for Sensory Data Analysis, Gold Coast Australia QLD Australia. 02 12 2014 02 12 2014*. ACM, New York, NY, USA, pp. 4-11.
- [8] Shaked Brody, Uri Alon, Eran Yahav. How Attentive are Graph Attention Networks?, in: *The Tenth International ICLR Conference 2022*.
- [9] Tuli, S., Casale, G., Jennings, N.R., 2022. TranAD. *Proc. VLDB Endow.* 15 (6), 1201-1214.
- [10] Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., He, Q., 2021. A Comprehensive Survey on Transfer Learning. *Proc. IEEE* 109 (1), 43-76.
- [11] Paszke, A., Gross, S., Chintala, S., Chanan, G., Yang, E., DeVito, Z., Lin, Z., Desmaison, A., Antiga, L., Lerer, A., 2017. Automatic differentiation in PyTorch. *The Thirty-first Annual Conference on Neural Information Processing Systems (NIPS)* (31).
- [12] Akiba, T., Sano, S., Yanase, T., Ohta, T., Koyama, M., 2019. Optuna: A Next-generation Hyperparameter Optimization Framework, 10 pp. <http://arxiv.org/pdf/1907.10902v1>.
- [13] Montgomery, D.C., 2019. *Introduction to statistical quality control*, Eighth edition ed. Wiley, Hoboken, NJ.
- [14] Zimmer, L., Kotz, S., Lovelace, C.R., 2000. Process Capability Indices in Theory and Practice. *Technometrics* 42 (2), 206. mittels Unüberwachtem Transfer Learning



MENSCH

Dieses Kapitel behandelt das Zusammenspiel zwischen Mensch und KI. Von der Integration von Expertenwissen in Algorithmen über die Förderung von Akzeptanz bei den Mitarbeitenden bis zur „Explainable“, also erklärbaren KI: dieses Kapitel beschreibt, wie man den Menschen optimal inkludiert.

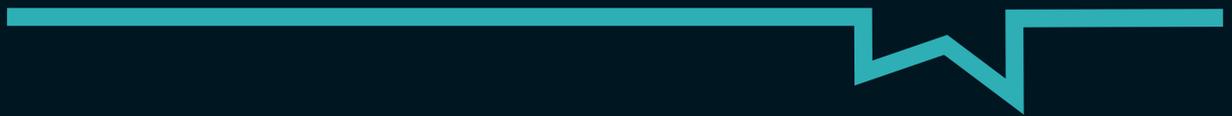
Der Mehrwert von KI ist vielfach von der Akzeptanz der Menschen abhängig, die mit ihr arbeiten, sie mit Expertenwissen versorgen oder die KI-Vorschläge umsetzen sollen. Eine Akzeptanzstudie bewertet das soziotechnische Zusammenspiel. Weiterhin werden das notwendige Change-Management zur Einführung von KI und darüber hinaus ein Beispiel für die Entwicklung eines KI-basierten Assistenzsystems erläutert. Nicht zuletzt wird Explainable AI als ein Ansatz für die Plausibilisierung von KI-Ausgaben präsentiert. Dieses Kapitel fasst somit entscheidende Ergebnisse aus dem Bereich Mensch und KI zusammen.

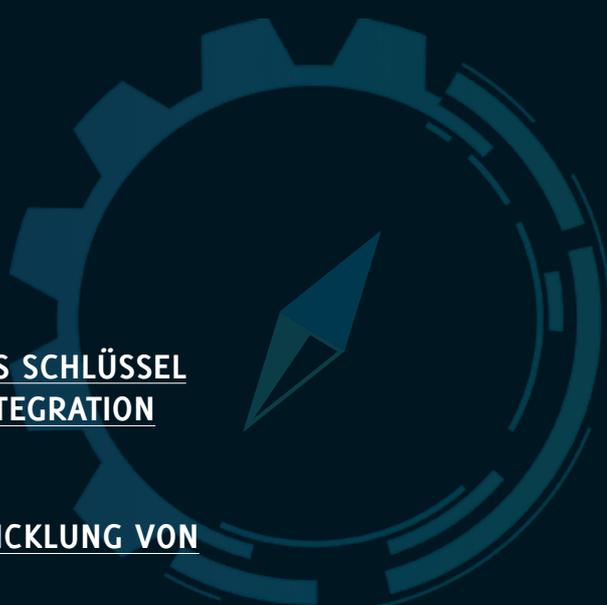


UND

KI

**WIE IM LEITFADEN
DARF AUCH HIER DIE
PERSPEKTIVE DES
MENSCHEN NICHT
AUSSER ACHT
GELASSEN WERDEN.
WIE SCHAFFEN WIR EINE
HYBRIDE INTELLIGENZ?**





194 CHANGE-MANAGEMENT ALS SCHLÜSSEL
ZUR ERFOLGREICHEN KI-INTEGRATION

ProKI Hannover

198 MENSCHENZENTRIERTE ENTWICKLUNG VON
KI IN DER PRODUKTION

GeMeKI

204 KI-BASIERTE SYSTEME IN FERTIGUNGS-
UND PRODUKTIONSUNTERNEHMEN

ProKI Ilmenau

208 MIT KI ZU EFFIZIENTEREN
WERTSCHÖPFUNGSPROZESSEN

ProKI Dresden

213 INTEGRATION VON EXPERTENWISSEN IN
KI-MODELLE

ProKINect

218 EINSATZMÖGLICHKEITEN VON KI IN DER
ARBEITSGESTALTUNG

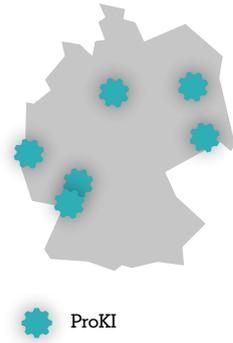
ProKI Dresden

224 ZUSAMMENSPIEL VON MENSCH UND
ROBOTIK

MetaLearn

229 VON DER MASCHINE BIS ZUR AKTION

TransKI



ProKI

CHANGE-MANAGEMENT ALS SCHLÜSSEL ZUR ERFOLGREICHEN KI-INTEGRATION

Marika Platz, Prof. Dr. Johann Nils Foege (Leibniz Universität Hannover, Area Strategic Management, Professur für Innovationsmanagement)

Effektives Change-Management erhöht die Erfolgchancen bei der Einführung von Künstlicher Intelligenz deutlich.

Die Integration von Künstlicher Intelligenz ist inzwischen für viele Unternehmen nahezu unverzichtbar ^[1, 2]. KI steigert nicht nur die Effizienz betrieblicher Abläufe, sondern eröffnet auch eine breite Palette neuer Geschäftsmöglichkeiten, was ihre Bedeutung im aktuellen Unternehmensumfeld weiter erhöht ^[3].

Genauso wichtig wie die Implementierung von leistungsfähiger KI ist allerdings auch die effektive Einführung dieser Technologie in die Unternehmensstrukturen ^[4]. Denn was nützt die fortschrittlichste KI, wenn sie von Mitarbeitenden weder genutzt noch akzeptiert wird?

Eine erfolgreiche KI-Einführung hängt somit nicht nur von der technischen Leistungsfähigkeit der Systeme ab, sondern vor allem von der Bereitschaft und Fähigkeit der Mitarbeitenden, diese neuen Werkzeuge effektiv zu nutzen ^[3, 5, 6]. Es wird deutlich, wie wichtig eine überlegte Umsetzung ist: Change-Management ist hier der entscheidende Faktor, um die Akzeptanz und Integration von KI innerhalb eines Unternehmens zu fördern und nachhaltig zu sichern ^[6]. Dieser Artikel beleuchtet deshalb die wichtigsten Aspekte des Change-Management im Zusammenhang mit der Einführung von KI. Schlussendlich kann ein gut durchdachtes

Change-Management dafür sorgen, dass die Mitarbeitenden die neuen Technologien nicht nur akzeptieren, sondern aktiv nutzen und davon profitieren.

Die gesamte Arbeitswelt hat sich im Laufe der Geschichte ständig weiterentwickelt. Neue Technologien, Marktanforderungen und gesellschaftliche Veränderungen haben immer wieder Anpassungen und Neuausrichtungen erfordert ^[7]. Schon früh wurde die Notwendigkeit von Change-Management erkannt, um diese Veränderungen strukturiert und erfolgreich zu gestalten. Change-Management beschreibt demzufolge einen Prozess, bei dem eine kontinuierliche Erneuerung der Ausrichtung, Struktur und Fähigkeiten eines Unternehmens stattfindet, um den permanent wechselnden Anforderungen des Marktes, der Kund:innen und der Mitarbeitenden gerecht zu werden ^[8]. Kurt Lewin und John Kotter haben die Entwicklung von Change-Management mit ihren Modellen besonders geprägt ^[9, 10, 11]. Beide Modelle bieten wertvolle Rahmenwerke für das Change-Management in Unternehmen, wobei Lewins Modell die grundlegende Struktur liefert und Kotters Modell detaillierte Schritte für eine erfolgreiche Umsetzung bietet.

Lewins Modell besteht aus drei Phasen: Unfreeze (Auf-tauen), Change (Verändern) und Refreeze (Wiedereinfrieren). In der Unfreeze-Phase wird das bestehende Gleichgewicht aufgebrochen, indem die Notwendigkeit der Veränderung kommuniziert und die Bereitschaft zur Veränderung geschaffen wird. In der Change-Pha-



se wird die eigentliche Veränderung implementiert. Hier sind Schulungen, kontinuierliche Kommunikation und Unterstützung entscheidend, um sicherzustellen, dass die Mitarbeitenden die neuen Systeme verstehen und nutzen können. In der Refreeze-Phase wird das neue Gleichgewicht stabilisiert und die Veränderungen werden in den Alltag integriert, um eine nachhaltige Implementierung sicherzustellen.

Kotter entwickelte ein achtstufiges Modell, das detaillierter auf die verschiedenen Phasen des Veränderungsprozesses eingeht^[10]. Die ersten drei Stufen zielen darauf ab, eine Grundlage für die Veränderung zu schaffen: ein Gefühl der Dringlichkeit zu erzeugen, eine Führungskoalition zu bilden und eine Vision für die Veränderung zu entwickeln. Die nächsten drei Stufen konzentrieren sich auf die Umsetzung der Veränderung: die Vision kommunizieren, Hindernisse aus dem Weg räumen und kurzfristige Erfolge sichtbar machen. Die letzten beiden Stufen betonen die Konsolidierung der Veränderungen und die Verankerung der neuen Ansätze in der Unternehmenskultur. Kotters Modell hebt die Bedeutung einer klaren Vision und einer starken Führung hervor, um den Veränderungsprozess erfolgreich zu gestalten.

Die Einführung von KI in Unternehmen stellt einen besonders tiefgreifenden Wandel dar, denn KI bringt nicht nur eine technologische Neuerung mit sich, sondern kann auch weitreichende Auswirkungen auf Prozesse, Mitarbeitende und die gesamte Unternehmensstruktur haben^[3]. Demzufolge stehen Mitarbeitenden der Einführung von KI oft mit gemischten Gefühlen entgegen. Auf der positiven Seite wird KI von Mitarbeitenden oft als unterstützend empfunden, da beispielsweise eine Automatisierung von wiederkehrenden oder zeitintensiven Aufgaben, Arbeitsprozesse vereinfacht und effizienter gestalten kann^[3]. Dadurch können sich Mitarbeitende auf anspruchsvollere Aspekte ihrer Arbeit konzentrieren und innovative Lösungen entwickeln, was wiederum zu einer Steigerung der Arbeitszufriedenheit führen kann.

Jedoch gibt es auch negative Aspekte, die Sorgen und Vorbehalte hervorrufen können. Einige Mitarbeitende finden KI kompliziert und schwer zu verstehen. Es besteht auch die Angst, durch KI ersetzt zu werden, da Mitarbeitende befürchten, dass automatisierte Systeme ihre Arbeitsplätze übernehmen könnten. Zudem gibt es die Auffassung, dass KI in manchen Bereichen unnötig ist und dass Mitarbeitende bestimmte Aufgaben ohne den Einsatz von KI selbst besser erledigen können^[6, 12, 13]. Ein weiteres kritisches Thema ist der Umgang mit großen Datenmengen. Viele Mitarbeitende sind besorgt über die Menge der von der KI gesammelten und verarbeiteten Daten, was Fragen zum Datenschutz und zur Privatsphäre aufwerfen kann.

Die Einstellung der Mitarbeitenden zur Einführung von KI wird nicht nur durch ihre persönliche Perspektive beeinflusst, sondern auch durch die Art und den Anwendungsbereich der KI im Unternehmen. KI kann von einfachen automatisierten Systemen bis hin zu autonom agierenden Maschinen reichen und sowohl den Arbeitsinhalt als auch den Arbeitskontext der Mitarbeitenden beeinflussen^[14]. Demzufolge existiert kein universelles Modell für die Einführung von KI in Unternehmen, da diese stark von individuellen Einstellungen und der spezifischen Art der KI-Anwendung abhängt. Die klassischen Modelle von Lewin und Kotter können eine nützliche Grundlage für die Implementierung von Veränderungen bieten. Angesichts der häufig bestehenden negativen Einstellungen und Perspektiven erfordert jedoch die Einführung von KI eine modifizierte Herangehensweise. Hierbei identifizieren wir drei entscheidende Anpassungen (siehe Abbildung 1):

Erstens wird in beiden Modellen die Einbindung der Mitarbeitenden erst in einem fortgeschrittenen Stadium der Veränderung vorgesehen. Dies entspricht dem tayloristischen Ansatz, nach dem Manager:innen die Aufgaben planen und die Mitarbeitenden diese ausführen^[15]. Es ist jedoch essenziell, die Mitarbeitenden von Beginn an in den Prozess zu integrieren. Denn eine frühzeitige Einbindung ermöglicht den Mitar-

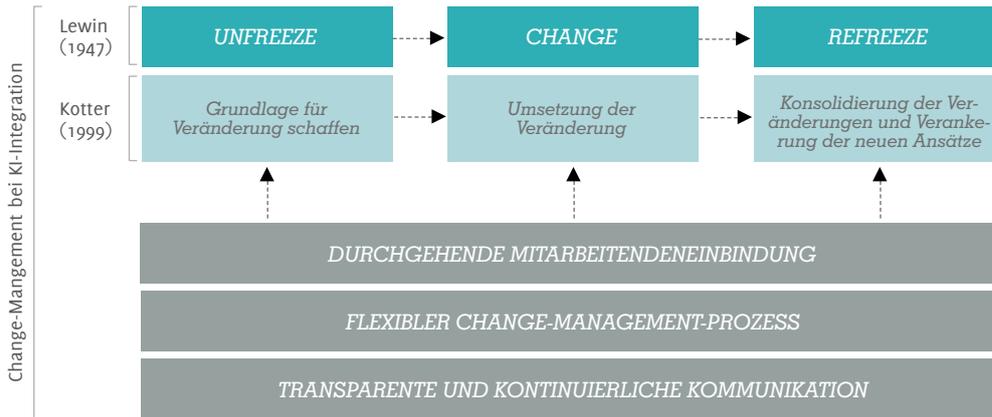


Abbildung 1: Change-Management bei KI-Integration

beitenden, ihre Perspektiven, Bedürfnisse und Ideen einzubringen, was dazu beiträgt, dass die KI tatsächlich einen relevanten Mehrwert generiert und nicht als störend oder überflüssig wahrgenommen wird [16, 17, 18]. Dies erhöht nicht nur den Nutzen der KI, sondern auch die Akzeptanz und die Bereitschaft der Mitarbeitenden, diese zu nutzen, sowie ihre Fähigkeit, die Technologie effektiv zu implementieren und anzuwenden. Die frühzeitige Einbindung der Mitarbeitenden reduziert zudem ihre Bedenken, steigert ihre Motivation und verbessert ihr Verständnis für die Funktionsweise und den Mehrwert der KI. Zudem fördert es ein Gefühl der Mitgestaltung und Eigenverantwortung, was auch zu einer positiveren Einstellung gegenüber der neuen Technologie führt und die Lernkurve verkürzt [19].

Zweitens folgen Change-Management-Prozesse historisch gesehen oft einem linearen und rigiden Plan, der im Voraus detailliert ausgearbeitet und dann schrittweise umgesetzt wird [10, 11]. Die Einführung von KI stellt jedoch besondere Anforderungen, da KI-Technologien sich rasch weiterentwickeln und ihre Implementierung sowohl unerwartete Herausforderungen als auch neue Chancen mit sich bringen kann [20]. Um erfolgreich KI einzuführen, ist daher ein flexibler Change-Management-Prozess von entscheidender Bedeutung. Diese Flexibilität ermöglicht es, Pläne schnell an veränderte Umstände anzupassen und auf neue Entwicklungen zu reagieren. Durch eine iterative Gestaltung der Strategien, basierend auf kontinuierlichem Feedback und neuen Erkenntnissen, kann das Change-Management effektiver auf die Bedürfnisse der Mitarbeitenden eingehen. Dies gewährleistet zugleich, dass die Implementierung von KI die strategischen Ziele des Unternehmens unterstützt. Darüber hinaus ist es

wichtig, dass die Flexibilität im Change-Management nicht als unstrukturiertes Vorgehen missverstanden wird. Vielmehr sollte sie durch klare Prozesse und Mechanismen unterstützt werden, die es ermöglichen, Änderungen gezielt und effizient umzusetzen, ohne dabei den Überblick oder die strategischen Ziele aus den Augen zu verlieren.

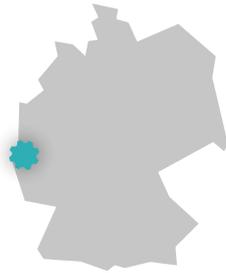
Drittens wurde bisher wenig Wert auf Kommunikation gelegt, doch eine transparente und kontinuierliche Kommunikation von Anfang an ist von zentraler Bedeutung. Bereits während der Entwicklungsphase von KI sollten alle Mitarbeitenden regelmäßig über den Fortschritt informiert werden, einschließlich jener, die nicht direkt von der KI-Implementierung betroffen sind [21]. Dies dient der Klarstellung der Ziele der KI, ihrer spezifischen Aufgaben und der Gewissheit, dass sie nicht dazu gedacht ist, menschliche Arbeitskräfte zu ersetzen. Eine solche Transparenz hilft dabei, Ängste und Missverständnisse zu reduzieren und die Akzeptanz zu fördern. Zudem sind intensive Schulungen, wie in beiden Modellen beschrieben, unerlässlich, um sicherzustellen, dass alle Mitarbeitenden die erforderlichen Fähigkeiten im Umgang mit KI entwickeln und Vertrauen in deren Nutzung gewinnen [6]. Hierbei ist es allerdings entscheidend, das Thema Datenschutz explizit anzusprechen, damit Mitarbeitende verstehen, wie ihre persönlichen Daten genutzt werden. Eine transparente Kommunikation über Datenschutzrichtlinien stärkt das Vertrauen der Mitarbeitenden und schafft ein positives Arbeitsumfeld, in dem die Mitarbeitenden sich sicher sein können, dass ihre persönlichen Informationen angemessen geschützt werden [22].



Zusammenfassend ist festzuhalten, dass Change-Management bei der Einführung von KI von entscheidender Bedeutung ist. Eine erfolgreiche Implementierung erfordert die frühe Einbindung der Mitarbeitenden, flexible Anpassungen im Change-Management-Prozess sowie intensive Schulungen, die auch das Verständnis für Datenschutz fördern.

Literatur

- [1] Benbya, H., Davenport, T. H., & Pachidi, S. 2020. Artificial intelligence in organizations: Current state and future opportunities. *MIS Quarterly Executive*, 19(4). https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3741983.
- [2] Raisch, S., & Krakowski, S. 2021. Artificial Intelligence and Management: The Automation-Augmentation Paradox. *Academy of Management Review*, 46(1): 192-210.
- [3] Davenport, T. H., & Ronanki, R. 2018. Artificial intelligence for the real world. *Harvard Business Review*, 96(1): 108-116.
- [4] Bendig, D., Wagner, R., Piening, E. P., & Foege, J. N. 2023. ATTENTION TO DIGITAL INNOVATION: EXPLORING THE IMPACT OF A CHIEF INFORMATION OFFICER IN THE TOP MANAGEMENT TEAM. *MIS Quarterly*, 47(4). https://www.wiwi.uni-muenster.de/ent/sites/ent/files/downloads/05_ra_10.25300_misq_2023_17152.pdf.
- [5] Mirbabaie, M., Brünker, F., Möllmann Frick, N. R. J., & Stieglitz, S. 2022. The rise of artificial intelligence - understanding the AI identity threat at the workplace. *Electronic Markets*, 32(1): 73-99.
- [6] Schneider, P., & Sting, F. J. 2020. Employees' Perspectives on Digitalization-Induced Change: Exploring Frames of Industry 4.0. *Academy of Management Discoveries*, amd.2019.0012.
- [7] Kröll, C., Nüesch, S., & Foege, J. N. 2021. Flexible work practices and organizational attractiveness in Germany: The mediating role of anticipated organizational support. *The International Journal of Human Resource Management*, 32(3): 543-572.
- [8] Moran, J.W. und Brightman, B.K. (2000), „Leading organizational change“, *Journal of Workplace Learning*, Vol. 12 No. 2, pp. 66-74. <https://doi.org/10.1108/13665620010316226>
- [9] Kotter, J. P. 1999. *John P. Kotter on what leaders really do*. Harvard Business Press. <https://books.google.com/books?hl=de&lr=&id=P3d8DVONPUkC&oi=fnd&pg=PA1&dq=kotter+hbr&ots=0-1miFVAiCb&sig=nvdeXoY3BaPAmLSDUUVKTD8RG-l>.
- [10] Kotter, J. P. 2007. *Leading change: Why transformation efforts fail*. *Museum management and marketing*: 20-29. Routledge.
- [11] Lewin, K. 1947. *Frontiers in Group Dynamics: Concept, Method and Reality in Social Science; Social Equilibria and Social Change*. *Human Relations*, 1(1): 5-41.
- [12] Hirsch-Kreinsen, H. 2014. Wandel von Produktionsarbeit - „Industrie 4.0“. *WSI-Mitteilungen*, 67(6): 421-429.
- [13] Kummer, T.-F., Recker, J., & Bick, M. 2017. Technology-induced anxiety: Manifestations, cultural influences, and its effect on the adoption of sensor-based technology in German and Australian hospitals. *Information & Management*, 54(1): 73-89.
- [14] Makarius, E. E., Mukherjee, D., Fox, J. D., & Fox, A. K. 2020. Rising with the machines: A sociotechnical framework for bringing artificial intelligence into the organization. *Journal of Business Research*, 120: 262-273.
- [15] Taylor, F. W. 2004. *Scientific management*. Routledge. <https://api.taylorfrancis.com/content/books/mono/download?identifierName=doi&identifierValue=10.4324/9780203498569&type=googlepdf>.
- [16] Anand, G., Ward, P. T., & Tatikonda, M. V. 2010. Role of explicit and tacit knowledge in Six Sigma projects: An empirical examination of differential project success. *Journal of Operations Management*, 28(4): 303-315.
- [17] Kim, Y. H., Sting, F. J., & Loch, C. H. 2014. Top-down, bottom-up, or both? Toward an integrative perspective on operations strategy formation. *Journal of Operations Management*, 32(7-8): 462-474.
- [18] Sting, F. J., & Loch, C. H. 2016. Implementing Operations Strategy: How Vertical and Horizontal Coordination Interact. *Production and Operations Management*, 25(7): 1177-1193.
- [19] Bailey, C., Madden, A., Alfes, K., & Fletcher, L. 2017. The Meaning, Antecedents and Outcomes of Employee Engagement: A Narrative Synthesis. *International Journal of Management Reviews*, 19(1): 31-53.
- [20] Von Krogh, G., Roberson, Q., & Gruber, M. 2023. Recognizing and Utilizing Novel Research Opportunities with Artificial Intelligence. *Academy of Management Journal*, 66(2): 367-373.
- [21] David, W. 1995. *Managing company-wide communication*. Chapman & Hall, Ltd. <https://dl.acm.org/doi/abs/10.5555/526232>.
- [22] Bhargava, A., Bester, M., & Bolton, L. 2021. Employees' Perceptions of the Implementation of Robotics, Artificial Intelligence, and Automation (RAIA) on Job Satisfaction, Job Security, and Employability. *Journal of Technology in Behavioral Science*, 6(1): 106-113.



MENSCHZENTRIERTE ENTWICKLUNG VON KI IN DER PRODUKTION

Manuel Belke (Werkzeugmaschinenlabor WZL der RWTH Aachen), Hossein Omid Beiki (Werkzeugmaschinenlabor WZL der RWTH Aachen),
Nina Pillen (YOUSE)

Durch eine menschenzentrierte Entwicklung eines KI-Systems wird nicht nur die Akzeptanz der Lösung unter Mitarbeitenden erhöht, sondern auch der Produktionsprozess verbessert.

ChatGPT hat nachweislich dazu beigetragen, KI in unserem Alltag zu verankern und für jedermann nutzbar zu machen. Insbesondere die textbasierte Arbeitswelt wurde durch diese zwar seit Langem theoretisch bekannten, aber erst heute einfach nutzbaren und zugänglichen Modelle stark beeinflusst. Doch wie sieht dies im Kontext der Produktion aus, wo keine sprachbasierten Modelle Einsatz finden? Wie akzeptieren Mitarbeitenden, dass sie aktiv an der Hebung des Datenschatzes beteiligt sind? Wie lässt sich ein System schaffen, dem Vertrauen geschenkt wird und das sich nativ in den Arbeitskontext einfügt?

Im folgenden Artikel möchten wir anhand eines Anwendungsbeispiels unseren mensch- bzw. werkenden-zentrierten Entwicklungsprozess für eine KI-Assistenz im Kontext der taktgebundenen Linienfertigung beschreiben.

Menschenzentrierte KI-Systementwicklung

Das Fachwissen der beteiligten Personen ist für einen effizienten Produktionsprozess entscheidend. Bereits bei der initialen Entwicklung des Prozesses stellen

Ingenieur:innen bei der Konstruktion des Bauteils sicher, dass alle Anforderungen erfüllt sind und eine effiziente Herstellung des Bauteils möglich ist. Bei der Grobplanung des Fertigungsprozesses kommt ebenfalls umfangreiches Wissen über Fertigungstechnologien zum Einsatz und bei der Programmierung der Maschinen ist tiefgreifendes Prozesswissen notwendig. Schlussendlich ist auch der nicht- oder nur teilautomatisierte Produktionsprozess stark vom Wissen und den fachlichen Fähigkeiten der menschlichen Maschinenführer:innen und Montagemitarbeitenden abhängig. Eine Formalisierung des Wissens und ein durchgängiger Informationsaustausch finden dennoch meistens nicht statt; es bleibt auf einzelne Personen konzentriert^[1].

Künstliche Intelligenz kann dabei vor allem in Form von Assistenzsystemen helfen. Obwohl dieser Technologie zugesprochen wird, große Produktivitätssteigerungen zu ermöglichen, wird sie derzeit oft nur in Einzellösungen eingesetzt. Eine breite Anwendung scheitert an vielen Hindernissen, wie fehlender KI-Expertise, hohen Risiken bei der Umsetzung neuer Anwendungsfälle, schlechter Übertragbarkeit der Lösungen oder zu kleinen Produktionsmengen, um überhaupt genügend Daten für ein KI-Training zu sammeln. Zudem basieren viele KI-Lösungen auf Black-Box-Modellen, bei denen die Ursache-Wirkungs-Beziehungen unklar sind. Die dabei fehlende Transparenz kann eine Hürde beim Aufbauen der Nutzerakzeptanz darstellen^[2].



Häufig sind die Systeme bereits vollständig entwickelt und trainiert, bevor sie in der Produktionsumgebung eingesetzt werden. So wird den Mitarbeitenden ein Einfluss auf die Gestaltung der KI und die Art und Weise, wie sie mit ihr interagieren, vorenthalten. Es zeigt sich, dass eine mit rein technischer Sicht gestaltete KI-Assistenz ihr Potenzial nicht immer voll entfalten kann, da diese Herangehensweise in der Praxis vermehrt zu Akzeptanz- und Nutzungsproblemen führen kann. Eine aktive Einbindung der zukünftigen Nutzenden in den KI-Entwicklungsprozess ermöglicht die Gestaltung einer gelungenen Interaktion zwischen Mensch und KI und kann somit den Implementierungsprozess stark vereinfachen, die Qualität der Ergebnisse sicherstellen und die Akzeptanz der Technologie bei den Mitarbeitenden erhöhen^[3, 4].

Zur Gestaltung der engen Interaktion zwischen Mensch und der hybriden Intelligenz im Sinne des Forschungsprojektes GeMeKI wurden für den Menschen mehrere zentrale Rollen identifiziert: Datengeber:innen, Kontrolleur:innen und Informationsnehmer:innen. Diese unterschiedlichen Touchpoints mit dem KI-System bieten große Chancen für die Verbesserung des Wissensmanagements, bergen aber auch einige Herausforderungen, die andere Mensch-Maschine-Interaktionen nicht oder nicht mehr besitzen. So muss aus der Perspektive des Human Centered Designs nicht nur die Benutzerfreundlichkeit auf der Arbeitsebene sichergestellt werden, sondern es müssen auch aktiv Vorbehalte gegenüber der neuen Technologie abgebaut werden^[5].

Um ein in der Praxis funktionierendes und akzeptiertes technologisches System zu entwickeln, ist es wichtig, die Nutzende von Anfang an und in möglichst vielen Phasen der Entwicklung immer wieder mit einzubeziehen. Gemeinsam lassen sich gezielt praxisbezogene, aber auch emotionale und ethische Herausforderungen (ELSI) identifizieren, die bei der Gestaltung des Systems direkt adressiert werden können. Ohne diese Teilhabe potenziert sich die Gefahr, dass die Nutzenden die kostspielige neue Technologie ablehnen.

Auch im Projekt GeMeKI wurde durch mehrere qualitative Untersuchungen festgestellt, dass eine beim Menschen liegende finale Entscheidungshoheit das Vertrauen in die KI positiv beeinflussen kann. Ein KI-System, das entmündigt, stößt nicht auf Akzeptanz^[6].

Akteure und Schritte bei der Entwicklung

Bei der menschenzentrierten Entwicklung von KI-Systemen in Produktionsumgebungen agieren drei Akteur:innengruppen miteinander (siehe Abbildung 1). Die erste Gruppe sind die Werker:innen, die den Prozess kennen, die Maschinen führen und die Fertigungsschritte durchführen und einen stabilen Produktionsprozess ermöglichen. Die zweite Gruppe sind die Interaktionsexpert:innen (UXler), die die Gestaltung der Mensch-KI-Interaktion methodisch begleiten, Ansprechpartner:innen für die involvierten Nutzenden sind und Konzepte für die Interaktion erarbeiten. Die dritte Gruppe sind die Programmierer:innen und Ingenieur:innen, die technische Expertise und Softwarekenntnisse vereinen und die KI-Umsetzung übernehmen.

Um die Fachkenntnisse der Gruppe der Werker:innen während des gesamten Entwicklungsprozesses einzubeziehen, verwendet GeMeKI verschiedene Methoden der menschenzentrierten Gestaltung. In der Planungsphase wird zunächst eine Kontextanalyse zur systematischen Erfassung der Arbeitsumgebung durchgeführt, die ergonomische, strukturelle, emotionale und soziale Faktoren und die Arbeitsbelastung dokumentiert. Im Anschluss folgt eine umfangreiche qualitative Interviewstudie mit dem Schwerpunkt KI-Akzeptanz, um Einstellungen, Ängste und Hoffnungen der Werker:innen gegenüber der neuen Technologie kennenzulernen. Sowohl die Kontextanalyse als auch die Akzeptanzstudie werden von den UXler:innen geleitet und in Zusammenarbeit mit den Werker:innen durchgeführt. Auf diese Schritte folgt eine von den UXler:innen moderierte Auseinandersetzung mit ethischen, rechtlichen und sozialen Aspekten (ELSA) des speziellen KI-Einsatzes im Kreise des gesamten

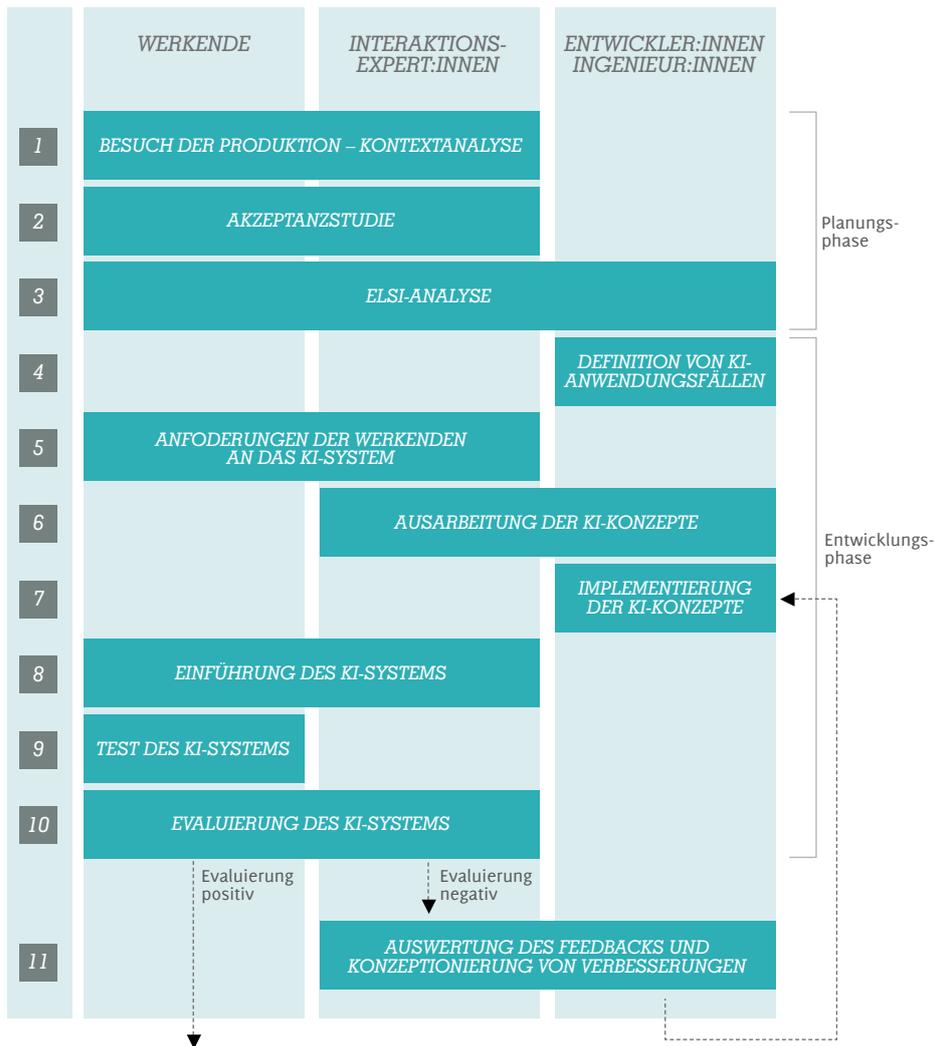


Abbildung 1: Prozessschritte der menschzentrierten Entwicklung

Forschungskonsortiums, um einen Konsens über eine verantwortungsvolle Ausgestaltung des KI-Systems unter allen Beteiligten zu schaffen. In einem Workshop wird ein gemeinsames Bild des umzusetzenden Systems erarbeitet, das im Weiteren die Grundlage bildet, um konkrete Herausforderungen in den Dimensionen Gerechtigkeit, Teilhabe, Transparenz, Selbstbestimmung, Fürsorge, Sicherheit, Selbstverständnis und Privatheit zu erarbeiten. In einzelnen Gruppen werden die Herausforderungen im nächsten Schritt bewertet. Zuletzt wird abgeleitet, welche Lösungen für die Herausforderungen bereits bestehen und welche noch erarbeitet werden müssen. Das so auch bei den technischen Entwickler:innen geschaffene Verständnis für ethische, rechtliche und soziale Themen bildet die Grundlage, um eine ganzheitliche menschzentrierte Systementwicklung zu ermöglichen, in der alle ein Ge-

spür für die Bedarfe der Nutzenden und die soziotechnologischen Auswirkungen des Systems mitdenken können. Dieses gemeinsame Verständnis ermöglicht die Hand-in-Hand-Entwicklung der drei Gruppen^[7].

In der Entwicklungsphase der Mensch-KI-Interaktion kommt bei GeMeKI ein Co-Design-Ansatz zum Einsatz. Die Nutzenden sind dabei nicht nur bei der Testung von Prototypen beteiligt, sondern auch bei der Ideenentwicklung und Ergebnisanalyse^[8]. Sie bringen ihr kontextuelles Wissen ein und ihre Belange werden gleichwertig neben technischen und wirtschaftlichen Faktoren in Entscheidungsprozesse einbezogen. Diese Mitbestimmung wird durch angemessene Entlohnung und ein Vetorecht für die Co-Entwickler:innen gesichert, das von den UXler:innen gegenüber der technologischen Entwicklung durchgesetzt wird.



Zu Beginn wird ein Interaktionskonzept in enghem Feedback mit den Werker:innen und den Entwickler:innen erarbeitet. Hierzu visualisieren die UXler:innen den IST-Zustand und erarbeiten gemeinsam mit den Werker:innen und den Entwickler:innen eine Vision des zukünftigen KI-integrierten Szenarios, das technische wie menschzentrierte Bedürfnisse verhandelt und vereint. Dieses Soll-Szenario wird im Folgenden immer weiter verfeinert und mündet in konkrete testbare Mock-ups, die mit den Nutzenden iterativ getestet und optimiert werden. Parallel arbeiten die Entwickler:innen an der technischen Machbarkeit und der Umsetzung des funktionsfähigen Demonstrators. Sobald das KI-System bzw. autonom nutzbare Elemente (wie die Datensammel-Interaktion) nutzbar sind, werden diese von den Werker:innen im Realkontext getestet und benutzt. Eine Begleitung der Einführung des Systems durch die UXler:innen sorgt für eine schnelle und gezielte Einarbeitung der Werker:innen in das neue System. Da erste Systeme meist noch viele Fehler aufweisen, ist es besonders ausschlaggebend, den beteiligten Werker:innen ihre Aufgabe als Systemtester:innen zu verdeutlichen und darüber zu informieren, dass ihr Arbeitstag ggf. nicht so läuft wie gewohnt. Eine intensive technische Betreuung auch von Langzeittests und die Möglichkeit, in kurzen Abständen Feedback an die UXler:innen zu geben sowie das zügige Erleben von Updates, die auf die beschriebenen Probleme reagieren, ist wichtig für die Motivation und eine gute Zusammenarbeit mit den testenden Werker:innen.

Umsetzung im Anwendungsfall Fügen

Im Falle von erhöhter Prozesskomplexität und unklarem Stückzahlpotenzial zeigt die industrielle Montage in der Regel einen niedrigen Automatisierungsgrad. Im Projekt GeMeKI wird eine KI-Applikation in der manuellen Kleinserienmontage von Elektromotoren bei der Firma Miele & Cie. KG untersucht. Diese Elektromotoren bestehen aus einem gelagerten Rotor und einem im Gehäuse integrierten Stator. Die Rotoren

werden an beiden Enden der Rotorwelle gelagert, wobei die Innenringe der Lager durch Kraftschluss fest mit der Rotorwelle verbunden sind. Die beiden Außenschalen der Lager werden in das Gehäuse verklebt. Dafür wird automatisch eine Klebeschicht auf die Lagerschalen aufgebracht, bevor der Rotor in das Gehäuse gefügt wird. Die Qualität der automatisch applizierten Klebeschicht ist dabei entscheidend, da im schlimmsten Fall die Lager und somit der Rotor sich vom Gehäuse lösen könnten. Das KI-System soll dazu beitragen, die Qualität der Klebeschicht zu beurteilen. Im Fall einer unzureichenden Qualität schlägt das System Maßnahmen zur Verbesserung der Qualität vor. Die Qualitätsbeurteilung erfolgt anhand eines Kamerabildes, das durch eine Kombination aus Kamera und entsprechender Beleuchtung aufgenommen wird. Da für das Training des KI-Modells Daten notwendig sind, kommt den Werker:innen im ersten Schritt die Aufgabe zu, diese Daten zu erzeugen. Das Entwickler:innenteam hat dazu die Idee entwickelt, die aufgenommenen Bilder auf einem Touchscreen anzuzeigen und über Buttons das Labeling zu ermöglichen. Die Werker:innen waren dem Labeling offen gegenüber, wobei die Integration in die vorhandenen Arbeitsabläufe wichtig war. Um dies zu gewährleisten, wurden zusätzlich zu den Buttons auf dem Touchscreen physische Drucktaster im Bewegungsraum der Werker:innen integriert.

Erkenntnisse aus der Entwicklung

Aus technischer Sicht hat eine zunächst suboptimale Ausrichtung der Kamerabeleuchtung, durch die die Werker:innen geblendet wurden, dazu geführt, dass die Beleuchtung abgedeckt wurde. Damit hat dann die Qualität der Kamerabilder drastisch abgenommen. Auch abseits der Interaktion mit dem KI-System muss die Integration aller neuen Komponenten akzeptiert werden, um nicht nur ein gutes Labeling der Daten zu erreichen, sondern auch die Nutzung der KI zu fördern, sodass die Produktivität gesteigert und der Ausschuss reduziert wird. Durch häufige Testphasen



während der Integration können frühzeitig Lösungen für Akzeptanzprobleme gefunden werden.

Für die Erzeugung eines vollständigen Datensatzes ist das konsequente Labeln der Bauteile entscheidend. Gleichzeitig führt das Labeln der Bauteile zu einer reduzierten Taktzeit der Werker:innen. Damit die Taktzeit eingehalten werden kann, ist eine kurze Reaktionszeit des Systems erforderlich. Die Werker:innen benutzen das System nur zuverlässig, wenn dieses den Arbeitsfluss nicht behindert und einwandfrei funktioniert. Das macht die Nutzung von Systemen im Prototypenstatus schwierig und es muss eine gesonderte Einweisung in das System geben, falls das System unter Inkaufnahme von Taktzeitverlusten genutzt werden soll.

Die Akzeptanzstudie hat eine grundsätzliche Offenheit der Werker:innen gegenüber der Nutzung von KI-Systemen gezeigt. KI-Systeme werden als Ergänzung und Werkzeug zur Verbesserung der eigenen Arbeit verstanden. Diese offene Haltung kann nur erreicht werden, wenn das System und deren Funktionsweise verstanden wird. Da KI-Systeme auf Daten beruhen, ist für die Entwicklung die Aufnahme der Daten entscheidend. Die Verbesserung des Produktionsprozesses kann umso größer ausfallen, je umfassender der Datensatz ist. Die umfassende Aufnahme von Daten birgt hier allerdings das Risiko der Rückverfolgbarkeit der Arbeitsleistung der einzelnen Werker:innen. Die Anonymisierung der Daten, um die Rückverfolgbarkeit zu verhindern, ist ein entscheidender Punkt für die Akzeptanz des Systems.

Für die Aufnahme großer Datenmengen wird ein ausgedehnter Zeitraum notwendig, in dem Daten aufgenommen und gelabelt werden, die KI aber noch nicht trainiert ist und keine Empfehlungen geben kann. Während dieses Zeitraums wurde den Werker:innen keine Rückmeldung über den Status der Datenaufnahmen gegeben. Diese fehlende Rückmeldung führte zu einem Verlust an Motivation, die Datenaufnahme konsistent durchzuführen. Es ist daher wichtig, eine

Abschätzung zu geben, welcher Anteil der notwendigen Daten bereits aufgenommen wurde, auch wenn diese Angabe gegebenenfalls während des Trainings des KI-Modells korrigiert werden muss.

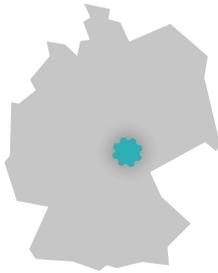
Abschließend lässt sich sagen, dass die menschenzentrierte Entwicklung von KI-Systemen in Produktionsumgebungen eine sorgfältige Einbindung der Nutzenden in allen Phasen des Entwicklungsprozesses erfordert. Die Akzeptanz und der Erfolg solcher Systeme hängen stark von der Transparenz, der Benutzerfreundlichkeit und der Berücksichtigung ethischer, rechtlicher und sozialer Aspekte ab. Bei dem Einsatz von KI-Black-Box-Modellen muss auf die Verständlichkeit und Nachvollziehbarkeit geachtet werden. Durch die aktive Beteiligung der Werker:innen, UXler:innen und Entwickler:innen im Rahmen eines Co-Design-Ansatzes kann ein gemeinsames Verständnis für die Anforderungen und Herausforderungen geschaffen werden, was wiederum die Qualität und Akzeptanz der KI-Lösungen erhöht. Begonnen werden kann die Entwicklung durch einen ELSA-Workshop, der ethische, soziale und rechtliche Aspekte betrachtet. Nur durch eine solche menschenzentrierte iterative Entwicklung kann sichergestellt werden, dass die Technologie nicht nur funktioniert, sondern auch gerne und effektiv genutzt wird und so auch die Produktivität steigern kann.

Literatur

- [1] Petrovic, Oliver; Belke, Manuel; Ochel, Janis; Brecher, Christian; Engels, Alexander; Bransky, Gregor et al. (2022): Hybride Intelligenz - Mensch und KI im Zusammenspiel/Development and introduction of production processes with AI assistance system - Hybrid intelligence: Human and AI in cooperation. In: wt 112 (05), S. 330-335. DOI: 10.37544/1436-4980-2022-05-60.
- [2] Jung, Maria, Werens, Samantha and von Garrel, Jörg. Vertrauen und Akzeptanz bei KI-basierten, industriellen Arbeitssystemen: Eine qualitative Analyse in Zeitschrift für wirtschaftlichen Fabrikbetrieb, vol. 117, no. 11, 2022, pp. 781-783. <https://doi.org/10.1515/zwf-2022-1134>
- [3] Irfan, M., Amin, O. & Marium, A. (2020). Conducting User Research for Designing Better Software Products. Journal Of Computing & Biomedical Informatics, 1(01), 49-65. <https://doi.org/10.56979/101/2020/44>
- [4] Kujala, S. (2003). User involvement: A review of the benefits and challenges. Behaviour & Information Technology, 22(1), 1-16. <https://doi.org/10.1080/01449290301782>



- [5] Chen, H., Gómez, C., Huang, C. & Unberath, M. (2022). Explainable medical imaging AI needs human-centered design: guidelines and evidence from a systematic review. *Npj Digital Medicine*, 5(1). <https://doi.org/10.1038/s41746-022-00699-2>
- [6] Bach, T. A., Khan, A. N., Hallock, H., Beltrão, G. & Sousa, S. (2022). A Systematic Literature Review of User Trust in AI-Enabled Systems: An HCI Perspective. *International Journal Of Human-computer Interaction*, 1-16. <https://doi.org/10.1080/10447318.2022.2138826>
- [7] Wessel, D. (2023). Gebrauchstaugliche Entwicklung von KI-Anwendungen. In *Künstliche Intelligenz in öffentlichen Verwaltungen: Grundlagen, Chancen, Herausforderungen und Einsatzszenarien* (pp. 67-82). Wiesbaden: Springer Fachmedien Wiesbaden.
- [8] C. Burns (2018). Human-centred design in Taylor & Francis eBooks, *eHealth research, theory, development: A multi-disciplinary approach*, L. van Gemert-Pijnen, R. Sanderman, S. M. Kelders, and H. Kip, Eds., London: Taylor and Francis, pp. 207-227.



KI-BASIERTE SYSTEME IN FERTIGUNGS- UND PRODUKTIONS- UNTERNEHMEN

WIE BESCHÄFTIGTE IN DER PRODUKTION KI-BASIERTE SYSTEME NUTZEN UND ANNEHMEN

Felipa Carrara, Jun. Prof. Dr. Elena Freisinger (Technische Universität Ilmenau, Fachgebiet Innovationsmanagement)

Die Annahmefähigkeit und Akzeptanz von KI-basierten Systemen hängt nicht nur von der Beschaffenheit der Nutzergruppe und dem Design des Systems ab, sondern ebenso von der Arbeitsbeziehung zwischen Mensch und KI.

In Anlehnung an Deloitte (2020) wird das verarbeitende Gewerbe beziehungsweise die Fertigungsindustrie bis 2025 eine der größten globalen Marktgrößen im Bereich KI haben. Ebenso wird angenommen, dass die Fertigungsindustrie einer der am schnellsten wachsenden Sektoren sein wird im Bereich der digitalen Transformation und KI-Implementierung, um intelligente Lösungen für das Management, die Produktion und die Logistik zu fördern^[1]. Ein wesentlicher Erfolgsfaktor für die Realisierung der Potenziale von KI-basierten Systemen ist das Adoptions- und Akzeptanzverhalten der Nutzenden. KI-basierte Systeme unterscheiden sich von herkömmlichen Technologien vor allem durch ihre Autonomie und ihre leistungsstarken Lernfähigkeiten, gepaart mit ihrer Unergründlichkeit^[2]. Das Adoptionsverhalten gestaltet sich dabei wesentlich komplexer als bei herkömmlichen Techno-

logien. So belegen beispielsweise einige Studien, dass Menschen KI-basierte Systeme ablehnen, selbst wenn diese menschliche Entscheidungen in Genauigkeit und Zuverlässigkeit übertreffen (in der Wissenschaft ist hier die Rede von einer „Aversion“, die vielschichtige Gründe hat). Solche Ablehnungen oder Aversionen können zu Fehlgebrauch, Missbrauch oder gar Nichtnutzung^[4, 5]; Parasuraman & Riley, 1997) und letztlich zu minderwertigen Entscheidungen führen^[6]. Um einen potenziellen Fehlgebrauch oder Missbrauch von KI-basierten Systemen zu vermeiden und Potenziale des KI-basierten umfänglich zu realisieren, ist es für KI Verantwortliche daher unerlässlich, sich mit dem Akzeptanz- und Adoptionsverhalten der Nutzergruppe auseinanderzusetzen.

In diesem Beitrag wird anhand einer vom Fachgebiet Innovationsmanagement der TU Ilmenau durchgeführten Studie das aktuelle KI-Nutzungsverhalten von Produktionsmitarbeitenden dargelegt sowie Faktoren, die das Nutzungs- und Akzeptanzverhalten beeinflussen. Die Studie besteht aus einer Umfrage und einem szenariobasierten Experiment, an der 167 Mitarbeitende deutscher Produktionsunternehmen teilgenommen haben. Anhand der Ergebnisse werden

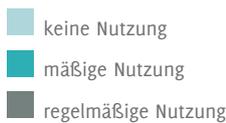
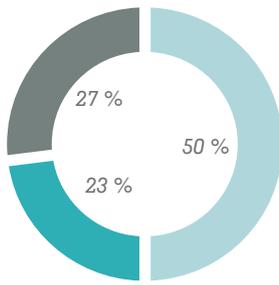


Abbildung 1 Aktuelle Nutzung von KI-basierten Systemen in deutschen Produktionsunternehmen

Handlungsempfehlungen abgeleitet, die KI-Verantwortliche dabei unterstützen, KI-basierte Systeme zu entwickeln, die Produktionsmitarbeitende gewillt sind zu nutzen und somit Fehlgebrauch, Missbrauch oder gar Nichtnutzung zu vermeiden.

Der Beitrag ist in drei Hauptkapitel gegliedert. Im ersten Kapitel wird die aktuelle Nutzung von KI-basierten Systemen in deutschen Produktionsunternehmen veranschaulicht. Im zweiten Kapitel wird das Meinungsbild der Produktionsmitarbeitenden gegenüber KI-basierten Systemen dargelegt. Im dritten Kapitel werden KI-spezifische Merkmale und Faktoren identifiziert, die das Verhalten der Beschäftigten hinsichtlich der Annahme und Akzeptanz von KI-Systemen beeinflussen können.

Aktuelle Nutzung von KI-basierten Systemen in deutschen Produktionsunternehmen

In der vom Fachgebiet Innovationsmanagement der TU Ilmenau durchgeführten Studie gaben 50 Prozent der Beschäftigten in deutschen Produktionsunternehmen an, keine KI-basierten Systeme am Arbeitsplatz zu nutzen (siehe Abbildung 1). Lediglich 23 Prozent gaben an KI-basierte Systeme mäßig und 27 Prozent KI-basierte Systeme regelmäßig zu nutzen.

Betrachtet man die Nutzung von KI-basierten Systemen, unterteilt in Arbeitsgruppen, etwa Produktionsleitung, Abteilungs- und Schichtleitung, Beschäftigte ohne Leitungsfunktion (siehe Abbildung 2), lässt sich erkennen, dass die Produktionsleitung am häufigsten

mit KI-basierten Systemen arbeitet, vor allem, um Zeit einzusparen. Hingegen verwenden Beschäftigte ohne Leitungsfunktion, also größtenteils jene, die direkt am Shopfloor arbeiten, am wenigsten KI-basierte Systeme.

Meinungsbild der Beschäftigten deutscher Produktionsunternehmen zu KI-basierten Systemen

Auch wenn in Anlehnung an die Studienergebnisse die Hälfte der Beschäftigten in der Produktion keine KI-basierten Systeme am Arbeitsplatz verwendet, verfügen sie über eine geringe Abwehrhaltung gegenüber innerbetrieblichen Veränderungen (Abb. 3) und sind vermehrt davon überzeugt, dass KI mehr Vorteile hat (Abb. 4). Zudem arbeiten sie gerne für innovative Unternehmen (Abb. 5) und verfügen über ein hohes Maß an Lernbegierde (Abb. 6). Folglich kann davon ausgegangen werden, dass Beschäftigte in der Produktion tendenziell offen sind für die Einführung und Verwendung KI-basierter Systeme am Arbeitsplatz.

Ein weiteres Ergebnis der Studie, das diese Annahme in gewisser Weise bestätigt, ist die neutrale und positive Gefühlslage, die mit der Einführung von KI-basierten Systemen einhergeht. Die Studie zeigt, dass sich Beschäftigte in der Produktion weder erkennbar ängstlich noch minderwertig noch gar nutzlos fühlen mit der Einführung von KI-basierten Systemen. Vielmehr gaben die Studienteilnehmenden vermehrt an, dass die Einführung von KI-basierten Systemen mit einer Steigerung der Arbeitszufriedenheit einherginge.

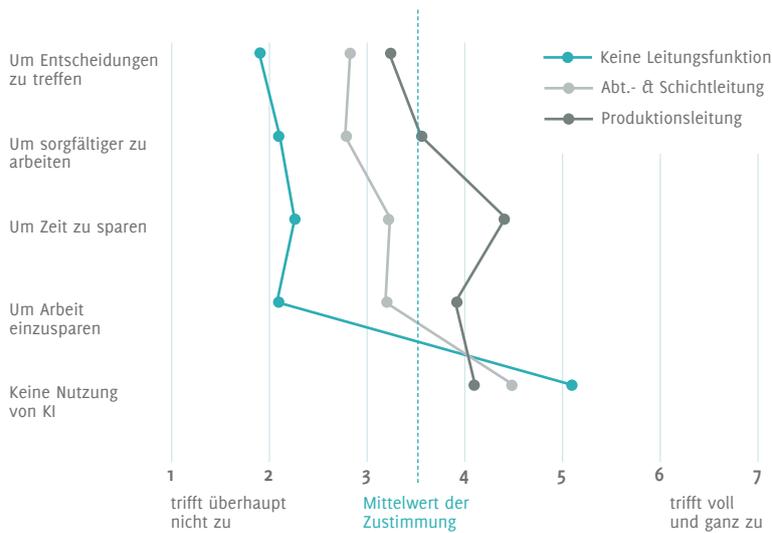


Abbildung 2 Nutzung von KI-basierten Systemen pro Bereich

Auch wenn die Diskussion und die mediale Aufmerksamkeit über mögliche Jobverluste durch die Einführung KI-basierter Systeme sehr präsent ist, so scheint diese Sorge unter den Beschäftigten in der Produktion weniger verbreitet zu sein.

KI-Adoptions- und Akzeptanzverhalten von Beschäftigten in der Produktion

Aktuelle Studien zeigen, dass Menschen KI-basierten Systemen unterschiedlich begegnen und dass die Beschaffenheit der Nutzergruppe, das Design des Systems selbst und die Arbeitsbeziehung zwischen Mensch und KI das Nutzungsverhalten beeinflussen können. Das vorherige Kapitel gab Aufschluss darüber, dass Beschäftigte in der Produktion tendenziell offen sind gegenüber der Verwendung KI-basierter Systeme am Arbeitsplatz und mit der Einführung eine tendenzielle Steigerung der Arbeitszufriedenheit einhergeht. Das Kapitel macht zudem deutlich, welche Art der Arbeitsbeziehung zwischen Mensch und KI förderlich oder hinderlich ist, wenn es um die Bereitschaft geht, KI anzunehmen.

Anhand der hier thematisierten Studie kann festgestellt werden, dass die hierarchische Arbeitsbeziehung zwischen Mensch und KI die Annahmefähigkeit signifikant beeinflusst. Genauer gesagt: Beschäftigte

sind in der Produktion eher gewillt, KI-basierte Systeme zu verwenden, die den Nutzenden untergeordnet sind und den Nutzenden die finale Entscheidung überlassen. Hingegen sind sie weniger gewillt, KI-basierte Systeme zu verwenden, die den Nutzenden übergeordnet sind und Aufgaben delegieren. Anders gesagt: Beratende KI-basierte Systeme, die finale Entscheidungen und die Kontrolle der Interaktion den Nutzenden selbst überlassen, werden eher angenommen und akzeptiert als KI-basierte Systeme, die den Nutzenden übergeordnet sind und Aufgaben delegieren.

Zusammenfassung und Handlungsempfehlungen

Die hier thematisierte Studie liefert wertvolle Anhaltspunkte für die Gestaltung und Einführung von KI-basierten Systemen in Produktionsunternehmen. Auch wenn die derzeitige Nutzung von KI-basierten Systemen noch recht gering ist, verfügen Beschäftigte in der Produktion über eine tendenziell positive Einstellung gegenüber KI-basierten Systemen am Arbeitsplatz. Während Ängste und Sorgen, am Arbeitsplatz von KI-basierten Systemen verdrängt zu werden, sich einer großen medialen Aufmerksamkeit erfreuen, so offenbart die hier thematisierte Studie, dass Beschäftigte in der Produktion diese Sorge weniger teilen. Ganz im Gegenteil, die neutrale bis positive



Gefühlslage, die mit der Einführung von KI-basierten Systemen einherzugehen scheint, wie beispielsweise die Steigerung der Arbeitszufriedenheit, kann eine erfolgreiche Implementierung und optimale Nutzung des Potenzials von KI unterstützen.

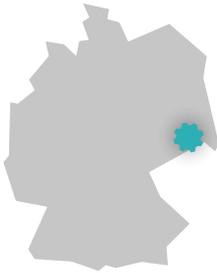
Das Annahme- und Akzeptanzverhalten von KI-basierten Systemen hängt dennoch stark mit dem Design des Systems selbst ab beziehungsweise von der Arbeitsbeziehung, die die Nutzenden mit diesem haben. Die hier thematisierte Studie veranschaulicht, dass Beschäftigte in der Produktion beratende KI-basierte Systeme eher annehmen, als solche, die den Nutzenden überlegen sind und Aufgaben delegieren. Basierend auf diesen Erkenntnissen werden folgende Handlungsempfehlungen an KI-Verantwortliche gerichtet, um die Einführung von KI-basierten Systemen effektiv zu begleiten und eine hohe Akzeptanz bei den Produktionsmitarbeitenden zu gewährleisten:

1. Um die Akzeptanz von KI-basierten Systemen zu fördern und zu erhöhen, empfehlen wir, die Beschäftigten in den Change-Prozess miteinzubeziehen und KI-basierte Systeme so zu gestalten, dass sie die Beschäftigten in ihrer Arbeit unterstützen und weniger vom Arbeitsplatz verdrängen.
2. Vor allem die hierarchische Arbeitsbeziehung zwischen Mensch und KI bestimmt die Annahmefähigkeit. Da beratende KI-basierte Systeme eher angenommen und akzeptiert werden als solche, die Aufgaben delegieren, empfehlen wir eine komplementäre und beratende Gestaltung von KI-basierten Systemen. Wir empfehlen, bevor Prozesse durch KI-basierte Systeme (gänzlich) automatisiert werden, KI-basierte Systeme sukzessiv einzuführen, um den Mitarbeitenden Zeit zu geben, sich mit dem System auseinandersetzen zu können.
2. Zudem empfehlen wir vor der Gestaltung der KI-basierten Systeme eine Mitarbeiteranalyse, um

zu evaluieren, wie und in welchen Bereichen KI-basierte Systeme die Beschäftigten unterstützen können. Dadurch kann die Akzeptanz gefördert und das Risiko einer Ablehnung, die negative betriebswirtschaftliche Folgen mit sich bringen kann, minimiert werden.

Literatur

- [1] Deloitte (2020): AI Enablement on the Way to Smart Manufacturing. Deloitte Survey on AI adoption in Manufacturing.
- [2] Berente, Nicholas, Gu Bin, Jan Recker, and Radhika Santhanam. 2021. "Special Issue Editor's Comment: Managing Artificial Intelligence." *MIS Quarterly* 45(3): 1433-1450. <https://doi.org/10.25300/MISQ/2021/16274>.
- [3] Venkatesh, Viswanath. 2022. "Adoption and Use of AI Tools: A Research Agenda Grounded in UTAUT." *Annals of Operations Research* 308(1): 641-652. <https://doi.org/10.1007/s10479-020-03918-9>.
- [4] Burton, Jason W., Stein, Mari-Klara, Jenson Blegind, Tina (2020). „A systematic review of algorithm aversion in augmented decision making”, *Journal of Behavioral Decision Making* (33): 220-239.
- [5] Parasuraman, R., & Riley, V. (1997). Humans and automation: Use, misuse, disuse, abuse. *Human Factors*, 39(2), 230-253. <https://doi.org/10.1518/001872097778543886>.
- [6] Berger, Benedikt, Martin Adam, Alexander Rühr, and Alexander Benlian. 2020. "Watch Me Improve—Algorithm Aversion and Demonstrating the Ability to Learn." *Business and Information Systems Engineering* 63(1): 55-68. <https://doi.org/10.1007/s12599-020-00678-5>



ProKI Dresden

MIT KI ZU EFFIZIENTEREN WERTSCHÖPFUNGS- PROZESSEN

MENSCHENZENTRIERTE UND PARTIZIPATIVE PROZESSOPTIMIERUNG IM UNTERNEHMEN

Carolin Böhme (Technische Universität Dresden)

Die Integration von Künstlicher Intelligenz in Unternehmensprozesse birgt enormes Potenzial – doch nur durch eine menschenzentrierte und partizipative Herangehensweise lassen sich nachhaltige und praxisnahe Lösungen entwickeln. Unser Ansatz zeigt: Indem wir die Bedürfnisse der Nutzenden in den Mittelpunkt stellen und sie aktiv in die Entwicklung einbeziehen, steigern wir nicht nur die Effizienz, sondern schaffen auch Akzeptanz und Vertrauen in neue Technologien.

Menschenzentrierte Technikentwicklung: Grundprinzipien und Relevanz

In einer zunehmend digitalisierten Welt ist die Umsetzung von digitalen Technologien, wie beispielsweise Künstlicher Intelligenz, in Unternehmensprozesse ein zentraler Hebel zur Steigerung der Effizienz und Wertschöpfung. Dabei gewinnen Ansätze der menschenzentrierten Technikentwicklung an Bedeutung. Nur wenn die Technologie auf die Bedürfnisse der Nutzenden abgestimmt ist, kann sie ihr volles Potenzial entfalten.

Exkurs: Die Grundprinzipien der menschenzentrierten Technikentwicklung

- **Verstehen der Nutzerbedürfnisse:** Durch umfassende Analysen, Interviews und Beobachtungen

werden die tatsächlichen Bedürfnisse der Nutzenden identifiziert. Dies verhindert Fehlentwicklungen und erhöht die Akzeptanz der Technologie.

- **Iterative Entwicklung:** Kontinuierliche Feedback-Schleifen ermöglichen es, die Technologie stetig zu verbessern und an die sich ändernden Bedürfnisse der Nutzenden anzupassen.
- **Interdisziplinäre Zusammenarbeit:** Experten aus verschiedenen Disziplinen wie Psychologie, Design und Ingenieurwesen arbeiten gemeinsam an der Entwicklung, um eine ganzheitliche Lösung zu schaffen.
- **Benutzerfreundlichkeit und Zugänglichkeit:** Die Technik muss leicht verständlich und für eine breite Nutzerbasis zugänglich sein.

Diese Prinzipien sorgen dafür, dass die entwickelten Ansätze nicht nur technisch ausgereift, sondern auch nutzerfreundlich gestaltet sind und somit einen hohen Mehrwert für den Nutzenden bieten. Die Akzeptanz und die Effizienz der Technik im praktischen Einsatz werden dadurch signifikant erhöht.

Partizipation: Begriff, Stufen und Formate

In einer Zeit, in der KI-Anwendungen die Unternehmenslandschaft revolutionieren, ist Partizipation ein wichtiger Erfolgsfaktor. Konkret bedeutet die Anwendung partizipativer Ansätze die aktive Einbeziehung



von Mitarbeitenden und relevanten Stakeholdern in den Entwicklungs- und Entscheidungsprozess. Dies geht weit über reine Information hinaus und umfasst das Konsultieren, Einbeziehen und Mitentscheiden aller Beteiligten. Die Bedeutung der Partizipation liegt vor allem in ihrer Fähigkeit, die Akzeptanz und das Vertrauen in neue Technologien zu fördern. Wenn Mitarbeitende in die Gestaltung und Optimierung von Prozessen eingebunden werden, fühlen sie sich ernst genommen und wertgeschätzt. Das führt nicht nur zu einer höheren Zufriedenheit und Motivation, sondern auch zu einer besseren Anpassung der Technologien an die realen Bedürfnisse und Herausforderungen im Arbeitsalltag. Darüber hinaus bringt Partizipation vielfältige Perspektiven und Ideen in den Entwicklungsprozess ein. Unterschiedliche Sichtweisen und Erfahrungen bereichern die Lösungsfindung und fördern innovative Ansätze. Dies ist besonders wichtig in einer Zeit, in der Unternehmen flexibel und anpassungsfähig bleiben müssen, um wettbewerbsfähig zu sein. Die aktive Einbindung aller Beteiligten schafft eine Kultur der Zusammenarbeit und des gemeinsamen Lernens. Dies stärkt nicht nur das Gemeinschaftsgefühl, sondern sorgt auch dafür, dass Veränderungen nachhaltiger und effektiver umgesetzt werden können. Die Risiken, die mit technologischen Umstellungen einhergehen, können durch frühzeitige Identifikation und gemeinschaftliche Problemlösung minimiert werden.

Exkurs: Partizipationsstufen und Partizipationsformate

Partizipationsstufen beschreiben den Grad und die Intensität der Einbeziehung von Stakeholdern (Abbildung 1).

- 1. Information:** Die Nutzenden werden über geplante Veränderungen informiert, ohne jedoch aktiv in den Entscheidungsprozess eingebunden zu werden.
- 2. Mitsprache:** Nutzenden können ihre Meinungen und Vorschläge einbringen, die Entwickler sind jedoch nicht verpflichtet, diese zu berücksichtigen.

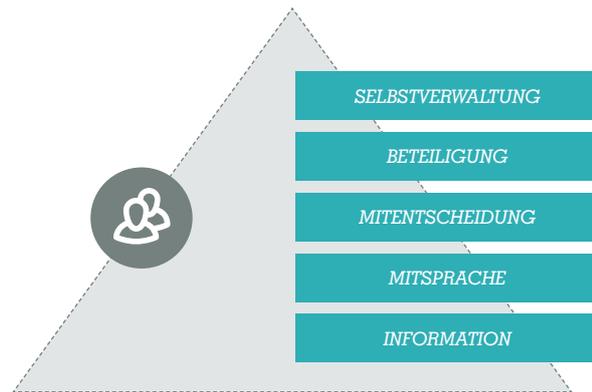


Abbildung 1: Partizipationsstufen

- 3. Mitentscheidung:** Nutzenden sind aktiv in den Entwicklungsprozess eingebunden und ihre Vorschläge werden ernsthaft in Betracht gezogen.
- 4. Beteiligung:** Nutzenden haben direkten Einfluss auf Entscheidungen und sind Teil des Entscheidungsgremiums.
- 5. Selbstverwaltung:** Nutzenden haben die volle Kontrolle und treffen Entscheidungen unabhängig von den Entwicklern.

Partizipationsformate hingegen beziehen sich auf die konkreten Methoden und Werkzeuge, die genutzt werden, um diese Einbindung zu realisieren.

- **Workshops:** In interaktiven Workshops können Nutzenden ihre Bedürfnisse äußern und gemeinsam mit Entwicklern an Lösungen arbeiten.
- **Umfragen und Interviews:** Diese Methoden bieten eine strukturierte Möglichkeit, direktes Feedback von den Nutzenden zu sammeln.
- **Pilotprojekte:** In realen Einsatzszenarien wird die Technik getestet und kontinuierlich verbessert.
- **Co-Creation-Sessions:** Entwickler und Nutzenden arbeiten gemeinsam an der Gestaltung und Verbesserung der Technologie.

Menschzentrierung in der Praxis – ein Erfolgsbeispiel

Unsere Herangehensweise (Abbildung 2) bei der menschzentrierten und partizipativen Prozessoptimierung wurde erfolgreich in mittelständischen Unternehmen umgesetzt. Dieses Best-Practice-Beispiel zeigt, wie eine praxisnahe Anwendung dieser Prinzipien zu signifikanten Verbesserungen führen kann.

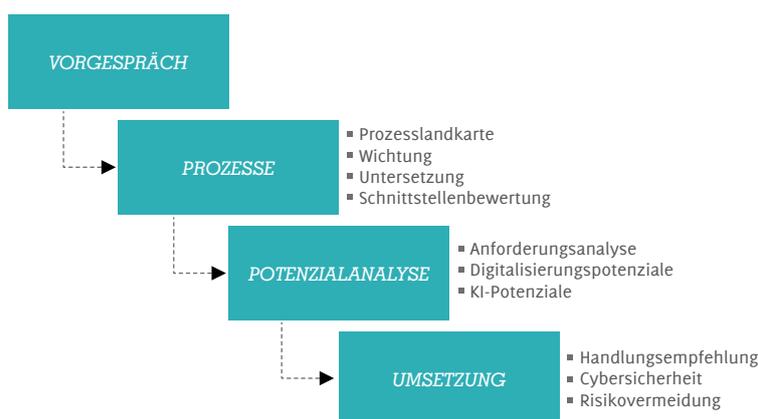


Abbildung 2: Schrittweise Herangehensweise im Projekt

Vorgespräch und Fragebogen

Der erste Schritt in unserem Projekt bestand aus einem ausführlichen Vorgespräch mit den Schlüsselpersonen des Unternehmens. Diese initiale Phase ermöglichte es uns, die spezifischen Problemstellungen des Unternehmens zu verstehen und die Aufgabenstellung klar zu definieren und abzugrenzen. Gleichzeitig wurden wichtige Unternehmensdaten erfasst und interne Verantwortliche sowie die relevanten Personenkreise (auch externe Stakeholder) festgelegt.

Partizipative Erarbeitung der Prozessstruktur

In einem ersten Workshop haben wir gemeinsam mit den Mitarbeitenden des Unternehmens eine umfassende Prozesslandkarte erstellt. Dabei wurden folgende Aspekte behandelt:

- **Identifikation der Prozesse:** Welche Prozesse sind im Unternehmen verankert? Welche gehören zu den Führungs-, Begleit- und Wertschöpfungsprozessen?
- **Schnittstellenbewertung:** Analyse der übergreifenden Schnittstellen, wie Medien- und Personalbrüche, sowie die Bewertung von Input- und Outputpunkten. Ziel war es, Engpässe und Softwarebrüche zu identifizieren und Ansätze zu ihrer Behebung zu definieren.

Nachfolgend erfolgte die gemeinsame Erstellung der Prozesslandkarte, in der auch die Verzweigungen der Prozesse und deren Verknüpfungen miteinander aufgezeigt werden konnten.

Bewertung der Prozesse

Die im Unternehmen vorhandenen Prozesse wurden anschließend auf Basis der vorhandenen Key-Performance-Indikatoren (KPI) und spezifischen Anforderungen des Unternehmens bewertet und gewichtet. Waren für den Prozess keine Indikatoren vorhanden, so wurden neue Möglichkeiten zur Erfolgs- und Wichtigkeitsmessung geschaffen. Dabei wurde ein partizipativer Ansatz verfolgt: Die Mitarbeitenden wurden aktiv einbezogen, um ihre Sichtweisen und Erfahrungen zu berücksichtigen. Dies half, potenzielle Ängste und Vorbehalte abzubauen und eine breite Akzeptanz der Veränderungen zu gewährleisten. Dazu wurden interaktive Workshops durchgeführt, die Vertreter:innen aller Abteilungen einbezogen. Es wurden im spielerischen Umfang unter Verwendung der 6-Hüte-Methode, des Walt-Disney-Thinking-Ansatzes und des Advocatus-diaboli-Ansatzes auch konkrete und spezifische Rollen geschaffen, die Kritik und negative Aussagen bewusst forderten, um Befürchtungen zu begegnen, seine Meinung etwa nicht frei äußern zu können.

Detaillierte Prozessuntersetzung

Für die wichtigsten Prozesse wurden detaillierte Beschreibungen erstellt, die folgende Punkte umfassten:

- **Input und Output:** Welche Informationen und Ressourcen sind erforderlich und welche Ergebnisse sind notwendig aus vorgelagerten Prozessen zu ziehen, um den gewählten Prozess zu starten?

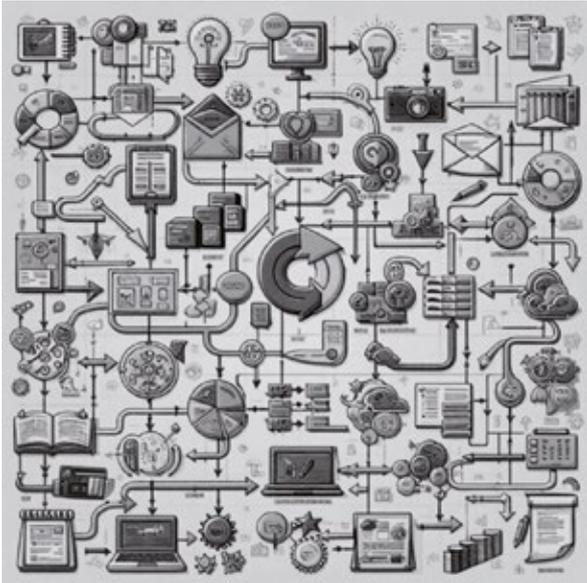


Abbildung 3: Beispielhafte Darstellung einer Prozesslandkarte (mit KI generiert)



Abbildung 4: Beispielhafte Darstellung einer SIPOC-Betrachtung (mit KI generiert)

- **Prozessschritte und Tätigkeitsbeschreibungen:** Detaillierte Beschreibung der einzelnen Arbeitsschritte und Aufgaben
- **Verantwortlichkeiten:** Klare Zuordnung der Verantwortlichen für jeden Prozessschritt
- **Notwendige Dokumente:** Identifikation und Bereitstellung aller erforderlichen Dokumente

SIPOC-Diagramm

Ein SIPOC-Diagramm (Suppliers, Inputs, Process, Outputs, Customers) half uns, die Schnittstellen und potenziellen Risiken der Prozesse zu beurteilen. Dies ermöglichte eine strukturierte Analyse und Optimierung der Prozesse.

KI- und Digitalisierungspotenzialanalyse

Ein weiterer zentraler Bestandteil unseres Projekts war die Analyse des Potenzials für KI- und Digitalisierungsmaßnahmen. Dabei wurde untersucht, welche Prozesse oder Prozessschritte von einem KI-Assistenzsystem profitieren könnten. Folgende Kriterien wurden berücksichtigt:

- **Infrastrukturelle Anforderungen:** notwendige technische Infrastruktur, vorhandene Infrastruktur und zu berücksichtigende Schnittstellen zu Bestandsprogrammen
- **Rechtliche Rahmenbedingungen:** Einhaltung gesetzlicher Vorgaben

- **Personenbezogene Aspekte:** Datenschutz und ethische Überlegungen

Handlungsempfehlungen und Umsetzung

Basierend auf den Ergebnissen der Analysen und Workshops erarbeiteten wir konkrete Handlungsempfehlungen. Diese umfassten sowohl technische als auch organisatorische und menschenbezogene Maßnahmen zur Optimierung der Prozesse. Besonderes Augenmerk legten wir auf die Sensibilisierung für Cybersicherheitsrisiken und die Implementierung geeigneter Maßnahmen zur Risikovermeidung.

Iteratives Vorgehen und Integration

Das iterative Vorgehen erwies sich als entscheidend für den Erfolg des Projekts. Durch die kontinuierliche Einbeziehung der Mitarbeitenden und die Anpassung an die spezifischen Gegebenheiten des Unternehmens konnten wir maßgeschneiderte Lösungen entwickeln.

Erkenntnis

Eine zentrale Erkenntnis aus unserem Projekt ist, dass die Einbeziehung aller „Betroffenen“ - inklusive externer Stakeholder - die Erfolgswahrscheinlichkeit signifikant erhöht und Vorbehalte gegenüber der neuen Technologie schneller abgebaut werden können als durch traditionelle Top-down-Ansätze, in denen sich die Mitarbeitenden und relevanten Stakeholder über-



gangen oder bezüglich ihrer Ängste und Vorbehalte nicht ernst genommen fühlen.

Diese praxisorientierte Anwendung der menschenzentrierten und partizipativen Prozessoptimierung zeigt, dass ein solcher Ansatz nicht nur theoretisch sinnvoll, sondern auch praktisch umsetzbar und erfolgreich ist. Durch die Kombination von menschenzentrierter Technikentwicklung, partizipativen Formaten und gezieltem Einsatz von KI konnten wir die Effizienz und Wertschöpfung des Unternehmens nachhaltig steigern.

Ergebnis und Lessons Learned: Was würden wir beim nächsten Mal anders machen?

Anpassung des Fragebogens

Eine wichtige Erkenntnis aus dem Projekt ist, dass viele Fragen besser in einem Gespräch und durch aktives Zuhören geklärt werden können als durch eine empirische Befragung. Es ist sinnvoll, als externe Mediatoren und Beratende stärker auf Gespräche einzugehen und Antworten aus Transkripten zu übertragen.

Die richtigen Fragen und Methoden

Partizipative Formate leben von Kreativität und einer lockeren, bewegten Herangehensweise. Die richtigen Fragen und Methoden sind entscheidend, um eine produktive Atmosphäre zu schaffen. Flexible und innovative Ansätze wie die Verwendung von Kreativtechniken und spielerischen Ansätzen, die Raum für offene Diskussionen und spontane Ideen bieten, sind dabei besonders wertvoll.

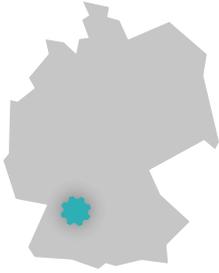
Individualität von Menschen und Unternehmen

Menschen und Unternehmen sind sehr individuell. Ein grobes Konzept ist hilfreich, aber es ist wichtig, situativ sehr reaktionsfähig zu sein. Fachexpertise sowohl methodischer als auch inhaltlicher Natur ist dringend notwendig, um auf die spezifischen Bedürfnisse einzugehen und maßgeschneiderte Lösungen zu entwickeln. Unser besonderes Augenmerk liegt deshalb zukünftig auch auf der Erweiterung unseres eigenen

Fundus an Herangehensweisen, Kreativtechniken, Kommunikation, Transferinstrumenten und Lösungsstrategien.

Fazit

Die menschenzentrierte und partizipative Prozessoptimierung mit Unterstützung durch KI bietet ein enormes Potenzial, Wertschöpfungsprozesse effizienter zu gestalten. Durch die aktive Einbindung der Nutzenden und eine iterative, auf den Menschen fokussierte Entwicklung können Unternehmen nicht nur die Akzeptanz neuer Technologien erhöhen, sondern auch deren Effektivität maximieren. Die Erkenntnisse aus der Praxis zeigen, dass ein solcher Ansatz nicht nur theoretisch sinnvoll, sondern auch praktisch erfolgreich ist.



INTEGRATION VON EXPERTENWISSEN IN KI-MODELLE

NACHHALTIGE STEIGERUNG VON ERKLÄRBARKEIT UND VERTRAUENSWÜRDIGKEIT

Jonathan Millitzer (Fraunhofer LBF), Wiebke Zenn (TRUMPF Werkzeugmaschinen SE & Co. KG), Sebastian Roeding (WITTENSTEIN SE), Valentin Mees (Fraunhofer LBF), Julia Butz (Fraunhofer LBF)

Mit der Integration von Domänenwissen unterschiedlicher Fachdisziplinen lässt sich die Erklärbarkeit und Vertrauenswürdigkeit KI-basierter Schlussfolgerungen nachhaltig steigern.

Expertenwissen in KI-Modellen nutzen

Bei der Zustandsüberwachung von Produktions- und Werkzeugmaschinen kann durch die Integration von Experten-, Anwendungs- und Instandhaltungswissen in KI-Modelle die Genauigkeit, Effizienz und Erklärbarkeit gesteigert werden. Das Wissen wird dabei aus unterschiedlichen Fachdisziplinen herangezogen, um die Leistungsfähigkeit der KI-Systeme zu verbessern. Expertenwissen kann beispielsweise in der Form von **statistischen Auswertungen und Kennzahlen** in KI-Modelle integriert werden. Instandsetzungs- und Fehlerprotokolle beinhalten dabei beispielsweise objektive Wahrscheinlichkeiten, die beschreiben, wie häufig ein Fehlerbild in einem bestimmten Zeitraum auftritt. Ein so durch Expertenwissen angereichertes KI-Modell kann dabei helfen, Muster und Trends in den Daten zu erkennen, die für algorithmische Modelle allein, insbesondere bei kleinem und unzureichendem Trainingsdatenumfang, möglicherweise nicht offensichtlich sind.

Darüber hinaus umfasst Expertenwissen das **Verständnis von Fehlerursachen und deren Folgefehlern**^[1]. Langjährige Servicekräfte wissen oft aus Erfahrung, welche spezifischen Symptome auf bestimmte Defekte hinweisen. Diese kausal-implikativen Zusammenhänge können bei der Erstellung präziser Diagnose- und Vorhersagealgorithmen berücksichtigt werden. Sie können KI-Modelle anleiten, nicht nur Anomalien zu erkennen, sondern auch deren Ursprung und mögliche Auswirkungen auf die Maschine zu verstehen und algorithmisch abzubilden. Experten sind ebenfalls geschult in der **Beobachtung von Phänomenen**, die mit bestimmten Fehlerbildern einhergehen und deren Interpretation ingenieursdomänenspezifisches Wissen erfordern^[2]. Das implikative Schlussfolgern und die Zuordnung möglicher Fehlerbilder ermöglicht es, auch aus begrenzten Daten Schlüsse zu ziehen und mögliche Hypothesen zu formulieren, die durch das Zustandsüberwachungssystem weiter untersucht und getestet werden können.

Das bestehende **Wissen über physikalische Gesetzmäßigkeiten und Zusammenhänge** ermöglicht es, wichtige Parameter physikalischer Gleichungen zu schätzen oder KI-Modelle mit physikalischem Wissen zur Verhaltensvorhersage zu verwenden^[3]. Dabei können beispielsweise physikalische Zusammenhänge von Kräften und Momenten sowie resultierenden Bewe-



gungsabläufen und Energieflüsse untersucht und mit der Erwartungshaltung der Expertinnen und Experten verglichen werden.

Die Kombination dieser vielfältigen Aspekte des Expertenwissens mit fortschrittlichen KI-Techniken führt zu einem robusten System, das nicht nur Daten analysiert, sondern auch kontext- und wissensbezogene Artefakte a priori integriert. Dadurch wird die Akzeptanz für die Nutzung erhöht und eine effektive Implementierung auch bei kleiner Datenbasis in der Praxis ermöglicht. Letztlich verbessert die Integration von Expertenwissen nicht nur die technische Leistungsfähigkeit, sondern trägt auch wesentlich zur praktischen Anwendbarkeit, geforderten Erklärbarkeit^[4] und Benutzerakzeptanz von KI-gestützten Überwachungssystemen bei.

Repräsentation von Wissen und unscharfes Schlussfolgern mit KI-Modellen

Für die Modellierung von Expertenwissen und dem Treffen von Schlussfolgerungen auch unter Berücksichtigung von Unsicherheit eignen sich verschiedene KI-Modellansätzen, die jeweils spezifische Eigenschaften und Fähigkeiten besitzen. Jedes dieser Modelle bietet unterschiedliche Vorteile bei der Integration von Expertenwissen unter anderem die effektive Handhabung von Unsicherheiten, wodurch sie - abhängig vom Anwendungsfall - besonders wertvoll für die Zustandsüberwachung von Werkzeug- und Produktionsmaschinen sein können. Zu den möglichen Modellen im Bereich der Zustandsüberwachung von Werkzeugmaschinen gehören unter anderem folgende Modellansätze:

Entscheidungsbäume und Random Forests sind nützlich, um klare Entscheidungsregeln in einem KI-Modell zu abbilden, die auf dem Expertenwissen basieren. Sie können einfach interpretiert werden, was die Akzeptanz und das Vertrauen in die Modellentscheidungen unter Fachleuten erhöht. Entscheidungs-

bäume sind besonders wertvoll, wenn es darum geht, die Bedeutung und den Einfluss einzelner Variablen zu verstehen, was eine direkte Verbindung zum Expertenwissen darstellt.

Probabilistische **Bayes'sche Netzwerke** sind geeignet, um Unsicherheiten zu handhaben und kausale, stochastische Beziehungen zwischen Variablen zu modellieren. Sie können verwendet werden, um Fachwissen bzgl. Kausalitäten zu kodieren und Vorhersagen unter Unsicherheit zu treffen, was in der Zustandsüberwachung häufig erforderlich ist. Bayes'sche Netzwerke können Wahrscheinlichkeiten für verschiedene Zustände und Ereignisse basierend auf den eingehenden Daten berechnen, was sie zu einem wertvollen Werkzeug für die Zustandsüberwachung macht.

Fuzzy-Logik-Systeme sind speziell darauf ausgelegt, mit Vagheit und unscharfen Informationen umzugehen. Fuzzy-Logik ermöglicht die Modellierung von Expertenwissen in Form von unscharfen Mengen und Regeln, die ähnlich zu menschlichem Denken und Entscheiden sind. Diese Modelle können gut verwendet werden, um unpräzise oder subjektive Bewertungen von Maschinenzuständen zu interpretieren und zu verarbeiten.

Expertensystem mit Unsicherheitsmetrik verwendet Wissensdatenbanken und Algorithmen, um Entscheidungen unter Berücksichtigung logisch-kausaler Zusammenhänge sowie einer geschätzten Informationsunsicherheit zu treffen. Diese Modelle können klassische Wahrscheinlichkeiten oder Kenngrößen der Evidenztheorie nutzen, um die Beweiskraft einer durch Expert:innen beschriebenen Schlussfolgerung, basierend auf den Eingangsdaten und einer Aussage- oder Prädikatenlogik, zu bewerten.

Physikinspirierte Modelle verwenden Konzepte und Methoden aus der Physik, um die Leistung von künstlichen Intelligenzsystemen zu verbessern. Sie können beispielsweise physikalische Gesetze und Prinzipien wie Erhaltungssätze oder dynamische Systemtheorien nutzen, um präzisere Vorhersagen zu treffen oder effizientere Algorithmen zu entwickeln.

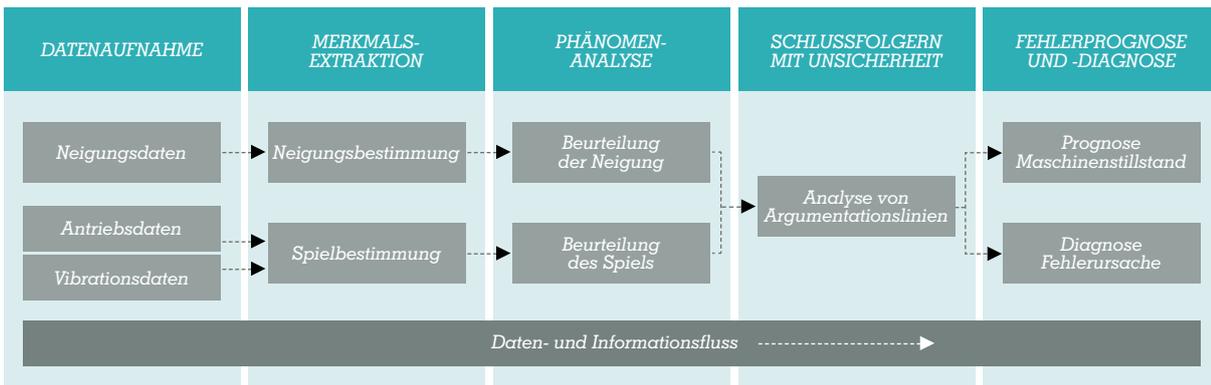


Abbildung 1: Daten- und Informationsfluss der in „ProKInect“ umgesetzten Zustandsüberwachung

Umsetzung am Beispiel einer 2D-Laserschneidmaschine

Am Beispiel einer 2D-Laserschneidmaschine wurde im Rahmen des BMBF-Verbundprojektes „ProKInect“ ein kollaboratives Zustandsüberwachungssystem realisiert, das Wissen unterschiedlicher Fachdisziplinen integriert. Ziel war es, basierend auf den Betriebsdaten der Laserschneidmaschine der Firma TRUMPF und eines sensorbestückten Planetengetriebes der Firma WITTENSTEIN Kenngrößen zu bestimmen, die im Sinne einer Fehlerfolgeprognose auf einen möglichen Maschinenausfall hinweisen sowie durch die Fähigkeiten zur Differenzialdiagnose mögliche Fehlerursachen aufzeigen.

Im Zuge der Vorbereitung der Umsetzung der KI-basierten Zustandsüberwachung wurde gemeinsam mit den Fachexperten von TRUMPF und WITTENSTEIN eine umfangreiche Fehlermöglichkeits- und Einflussanalyse (FMEA) durchgeführt, wobei mögliche Fehlerursachen auf Bauteilebene beschrieben und resultierenden Folgefehlern auf Komponenten, Teil- und Gesamtsystemebene zugeordnet wurden. Die beschriebenen Zusammenhänge sowie statistische Auswertungen von Instandsetzungs- und Fehlerprotokollen wurden zur Erstellung eines Bayes'schen Netzwerkes genutzt. Mithilfe des Bayes'schen Netzwerkes konnten so kritische Fehlerwirkketten klassifiziert werden, die eine hohe Auftretenswahrscheinlichkeit aufweisen und/oder kritische Auswirkungen, z. B. einen ungeplanten Maschinenstillstand, zur Folge haben. Diese probabilistische Systemfehler- und Zuverlässigkeitsanalyse erlaubte ebenfalls die Auswahl der technischen Systemgrenzen der in „ProKInect“ umgesetzten Zustandsüberwa-

chung. Hierzu zählen die Positionierachsen sowie die Aufstellbedingungen der 2D-Laserschneidmaschine.

Abbildung 1 zeigt eine vereinfachte Darstellung des Daten- und Informationsflusses der im Verbundprojekt „ProKInect“ umgesetzten KI-basierten Zustandsüberwachung. Nach der Aufnahme und Vorverarbeitung von Neigungs-, Antriebs- und Vibrationsdaten erfolgt die Extraktion von individuellen, messbaren Eigenschaften- und Merkmalsattributen auf Basis **physikalischer Gesetzmäßigkeiten und Zusammenhänge**, die zur weiteren Analyse verwendet werden. Zur Beurteilung der gewonnenen Merkmale wurden in „ProKInect“ trainierbare **Fuzzy-Logik-Systeme** (ANFIS) eingesetzt, die mittels linguistischer Regeln konkrete Schlussfolgerungen zur Kritikalität eines Phänomens ausgeben. Bei unsicherer Informationslage sind diese KI-Modelle ebenfalls in der Lage, Vagheit und Unschärfe nach subjektiver Einschätzung der Expertinnen und Experten von TRUMPF und WITTENSTEIN zu quantifizieren. Die Prognose eines potenziellen Maschinenstillstandes sowie die Diagnose möglicher Fehlerursachen erfolgte in „ProKInect“ mithilfe eines **Expertensystems**, das auf Basis von Fachwissen formulierte Ursache-Wirkung-Beziehungen („Wenn-dann-Regeln“) in einer Wissensbasis migriert. Daraus resultierende Argumentationslinien werden mithilfe evidenztheoretischer Kennzahlen bewertet, die eine Erweiterung der klassischen Wahrscheinlichkeitstheorie darstellen und die die Quantifizierung der vorliegenden Informationsunsicherheit ermöglichen.

Abbildung 2 stellt die prinzipiellen Möglichkeiten zur Folgefehlerprognose und Fehlerdiagnose entlang der technischen Hierarchie der 2D-Laserschneidmaschine

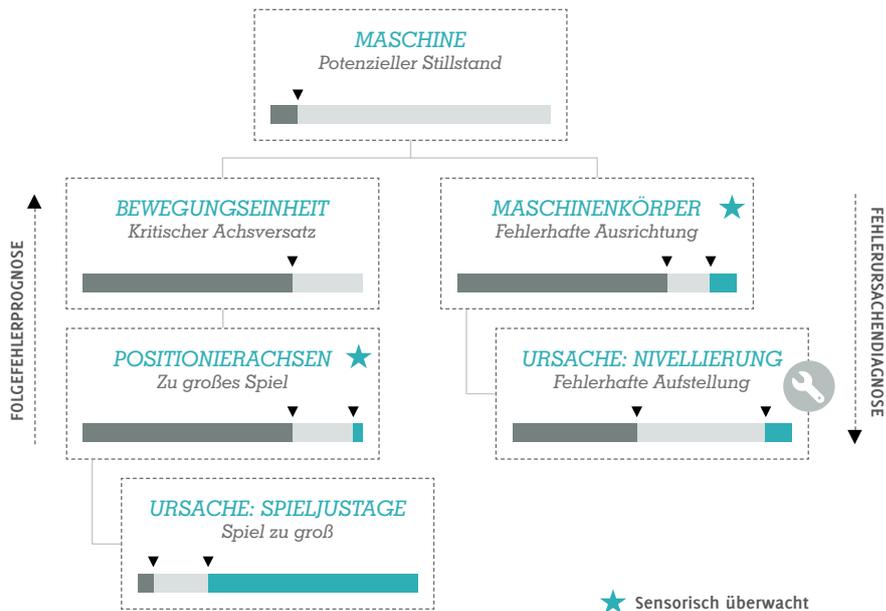


Abbildung 2: Prognose eines potenziellen Maschinenstillstandes und Diagnose einer möglichen Fehlerursache in „ProKInect“

aus „ProKInect“ exemplarisch dar. Zur Bewertung eines Fehlerbildes können jeweils drei Kennwerte der Evidenztheorie dienen: Die Beweiskraft, dass der Fehler definitiv vorliegt (roter Balken), die Argumente dafür, dass ein Fehler definitiv ausgeschlossen werden kann (grüner Balken), sowie die verbleibende Informationsunsicherheit (grauer Balken). Das dargestellte Beispiel zeigt auf, dass hinsichtlich der Prognose eines potenziellen Maschinenstillstandes eine große Unsicherheit besteht und dass somit weitere Informationsquellen zur Steigerung der Prognosegenauigkeit hinzugezogen werden müssen. Ferner deutet die Diagnose der Fehlerursachen, die zur Vorbereitung eines Serviceeinsatzes hinzugezogen werden können, auf eine fehlerhafte Nivellierung hin.

Nutzen

Die Integration von Expertenwissen in KI-Modelle zur Zustandsüberwachung von Werkzeugmaschinen bietet zahlreiche Vorteile, die die Erklärbarkeit und Nachvollziehbarkeit der KI-gestützten Entscheidungsfindung verbessern. Durch die A-priori-Integration von empirischem und erfahrungsabhängigem Wissen kann die **Zuverlässigkeit und Präzision** der Überwachungssysteme - insbesondere bei geringem Trainingsdatenbestand - erheblich gesteigert werden. Durch die Einbeziehung von tiefgehendem, domänenspezifischem

Wissen können KI-Modelle feinere Nuancen in den Daten erkennen, die sonst möglicherweise übersehen würden. Dies führt zu genaueren Diagnosen und einer effektiveren Vorhersage von potenziellen Problemen, bevor sie zu ernsthaften Maschinenausfällen führen. Ein weiterer Vorteil ist die Reduktion von Fehlalarmen, die häufig bei rein datengetriebenen Modellen auftreten. Die auf Expertenwissen und Algorithmik gleichermaßen basierende **Quantifizierung der Unsicherheit** hilft, die Modelle so zu kalibrieren, dass sie relevante von irrelevanten Anomalien unterscheiden können. Dies erhöht die Betriebseffizienz, da Wartungsteams gezielter eingesetzt werden können und weniger Zeit mit der Untersuchung von falschen Alarmen, speziell bei unsicherer Informationslage, verbringen müssen.

Darüber hinaus ermöglicht die Integration von Expertenwissen eine **verbesserte Anpassungsfähigkeit** der KI-Modelle an spezifische Betriebsbedingungen und Maschinentypen. Experten können ihr Wissen über besondere Betriebsbedingungen oder maschinenspezifische Eigenheiten in die Modellbildung einfließen lassen, was die Universalität und Anpassungsfähigkeit der Überwachungssysteme erhöht.

Die Nutzung von Expertenwissen trägt darüber hinaus zur **schnelleren Entwicklung und Implementierung** von KI-Modellen bei. Da Experten oft Muster und



Zusammenhänge erkennen, die in den reinen Daten nicht sofort sichtbar sind, können sie den Lernprozess der Modelle beschleunigen und deren Lernkurve steiler gestalten. Das in den KI-Modellen kodierte Wissen trägt dabei unmittelbar zur nachhaltigen Digitalisierung des reichhaltigen Wissensschatzes von Expertinnen und Experten bei. Dies führt bei einer Anpassung der Modelle auf ähnliche Derivate oder Fragestellungen zu einer schnelleren Einsatzbereitschaft der KI-Systeme und einer zügigeren Realisierung präventiver Wartungsmaßnahmen.

Abschließend verbessert die Einbindung von Expertenwissen **die Akzeptanz und das Vertrauen** in KI-basierte Überwachungssysteme unter den Endnutzenden. Wenn Techniker und Ingenieure sehen, dass ihre eigene Expertise und ihr Erfahrungsschatz in die Systeme einfließen, sind sie eher bereit, diese Technologien zu nutzen und sich auf deren Urteile zu verlassen. Dies fördert neben einer vertrauensvollen Zusammenarbeit von Menschen und KI ebenfalls die effektive und harmonische Integration von KI in die täglichen Betriebsabläufe.

Herausforderungen und Zukunftsaussichten

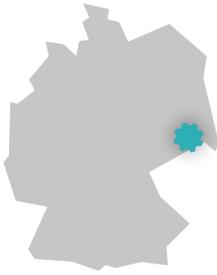
Aktuelle Herausforderungen und Technologieperspektiven im Bereich der Integration von Expertenwissen in KI-Modelle für die Zustandsüberwachung sind vielfältig und bieten sowohl technische als auch organisatorische Ansatzpunkte.

Eine der größten **Herausforderungen ist die methodische Erhebung und Formalisierung von Expertenwissen**. Während Expertinnen und Experten oft über umfangreiches implizites Wissen verfügen, kann es schwierig sein, dieses Wissen in eine Form zu überführen, die von einem KI-Modell genutzt werden kann. Die Entwicklung von Techniken zur Wissensextraktion, die effektiv und effizient menschliches Fachwissen in maschinenverständliche, einheitliche Formate übersetzen, ist daher von entscheidender Bedeutung. Die **Technologieperspektiven** umfassen die Entwick-

lung von hybriden Modellen, die sowohl maschinelles Lernen als auch regel- und wissensbasierte Systeme umfassen. Solche Modelle könnten die Stärken beider Ansätze auch bei kleiner Datenmenge vereinen: die Mustererkennungsfähigkeiten des maschinellen Lernens und das kausale, regelbasierte Verständnis von Expertensystemen, das a priori in den Modellen berücksichtigt wird. Während maschinelles Lernen hervorragend darin ist, Muster in Daten zu erkennen, können regelbasierte Expertensysteme dazu beitragen die „Warum?“-Frage zu beantworten, die oft entscheidend für das Verständnis der KI-Schlussfolgerungen sind. Damit leisten hybride Modelle einen Beitrag zur fortlaufenden Weiterentwicklung von Erklärbarkeit und Transparenz von KI-Systemen. Dies fördert nicht nur das Vertrauen der Nutzenden, sondern ermöglicht es auch, die Entscheidungsfindung der KI besser zu verstehen und zu überprüfen. Technologien wie XAI (Explainable Artificial Intelligence) werden in diesem Kontext immer wichtiger, um die Akzeptanz und Effektivität von KI-Systemen in der Industrie zu erhöhen.

Literatur

- [1] S. Kupjetz, W. Zenn and S. Röding, „Presentation of a causal model of relevant failure patterns for the development of knowledge-based AI models using the example of machine tools,” 31. VDI-Fachtagung Technische Zuverlässigkeit 2023, Nürtingen, Germany, <https://doi.org/10.24406/publica-1792>
- [2] W. Zenn, J. Butz and J. Millitzer, „Knowledge-Based AI Model for the Detection of Pinion Wear,” 2023 7th International Conference on System Reliability and Safety (ICRSRS), Bologna, Italy, 2023, pp. 428-433, Knowledge-Based AI Model for the Detection of Pinion Wear | IEEE Conference Publication | IEEE Xplore
- [3] W. Zenn, A. Keck, M. Beck, S. Herold and T. Melz, „Automated backlash determination on rack-and-pinion drives,” 2023 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), Seattle, WA, USA, 2023, pp. 1202-1207, Automated backlash determination on rack-and-pinion drives | IEEE Conference Publication | IEEE Xplore
- [4] DIN, DKE (2022): Deutsche Normungsroadmap Künstliche Intelligenz (Ausgabe 2); URL: www.din.de/go/normungsroadmapki



ProKI Dresden

EINSATZMÖGLICHKEITEN VON KI IN DER ARBEITSGESTALTUNG

Edgar Scherstjanoi (TU Dresden Fakultät Maschinenwesen Institut für Technische Logistik und Arbeitssysteme)

Die rasante Weiterentwicklung von Technologien der Künstlichen Intelligenz, insbesondere von Methoden des maschinellen Lernens, führt zu einer großen Auswahl an industriellen Einsatzmöglichkeiten. Auch die Arbeitswissenschaft kann aus diesem enormen Potenzial schöpfen. In diesem Beitrag soll mit praktischen Beispielen aus der Forschung gezeigt werden, wie KI einen bedeutenden Beitrag bei der menschenzentrierten Gestaltung von Arbeit leisten kann.

Die Arbeitswissenschaft forscht zur Analyse und Gestaltung von Arbeitsprozessen. Das übergeordnete Ziel ist es, die Erwerbsarbeit und die privatwirtschaftliche Arbeit zu verbessern. Bei der Analyse eines Arbeitsprozesses wird die Interdisziplinarität der Arbeitswissenschaft deutlich. Folgerichtig existieren auch viele verschiedene Anknüpfungspunkte für den Einsatz von KI-Technologien. Die intensive Erforschung aus unterschiedlichen Fachrichtungen hat dazu geführt, dass mittlerweile eine große Auswahl erprobter Methoden zur Verfügung steht, die durch geeignete Adaption für die Arbeitsgestaltung eingesetzt werden können.

Der Prozess der „Arbeit“ versteht sich in der Arbeitswissenschaft als „[...] jedes ziel- und zweckgerichtete Handeln zur Erzeugung von Gütern und Denkleistung“^[1].

Zur Verdeutlichung der Wechselwirkung der einzelnen Elemente eines Arbeitssystems ist das Strukturschema menschlicher Arbeit dienlich, wie in Abbildung 1 dargestellt. Die Beschreibung des Arbeitsplatzes umfasst die Darstellung aller relevanten Elemente und deren Beziehung zueinander.

Die Erforschung der Beziehung der einzelnen Elemente im Arbeitssystem führt zu einer Kategorisierung verschiedener arbeitswissenschaftlicher Gestaltungsfelder: Neben (a) der Gestaltung der Arbeitsaufgabe wird die Konfiguration der Schnittstelle zwischen dem Menschen und einem Arbeitsmittel als (b) interaktionsergonomische Gestaltung, die geometrische Auslegung davon wiederum als (c) anthropometrisches und biomechanisches Gestaltungsfeld bezeichnet. Wird ein Verbund mehrerer Arbeitssysteme betrachtet, entsteht auf der Makroebene das (d) Gestaltungsfeld der Arbeitsorganisation. Die gezielte Optimierung von Einflüssen wie Lärm, Temperatur, Vibration, Gefahrstoffe, Farbe oder Strahlung wird als (e) Gestaltung der Arbeitsumwelt verstanden.

Für jedes Gestaltungsfeld sind Methoden verfügbar, die auf arbeitswissenschaftlichen Erkenntnissen basieren und bereits in der industriellen Praxis eingesetzt werden. Durch die intensive Erforschung Künstlicher Intelligenz können diese Methoden nun noch effizienter und effektiver zur Gestaltung der Arbeit beitra-

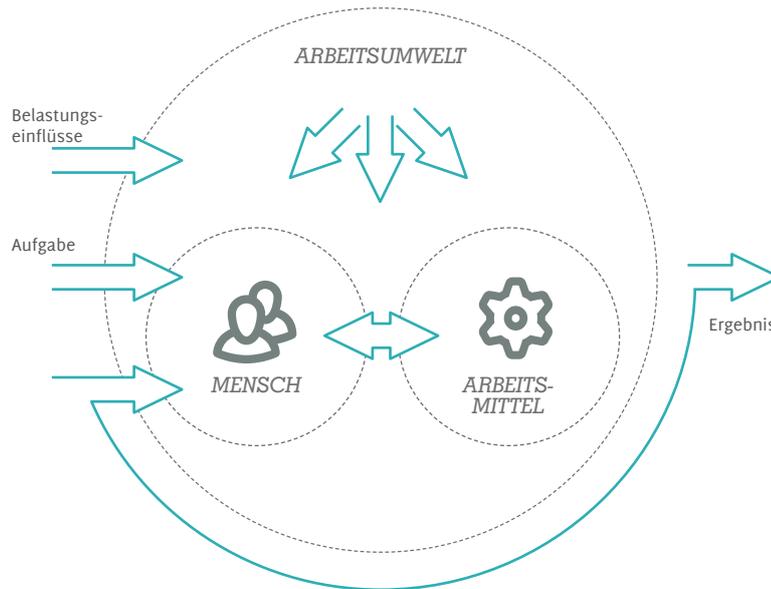


Abbildung 1. Strukturschema menschliche Arbeit. Im Zentrum der Arbeit steht die Wechselwirkung zwischen dem Menschen und dem Arbeitsmittel zur Erfüllung einer Aufgabe und Bewirkung eines Ergebnisses. Diese Arbeitsausführung ist in die Arbeitsumwelt eingebunden, wodurch organisatorische und soziale Belastungen die Ausführung der Arbeit beeinflussen. Auch das Ergebnis der Arbeit hat Einfluss auf die Umsetzung der Arbeitsaufgabe. Sollten bspw. Menge oder Qualität nicht zufriedenstellend sein, können die Aufgabe oder die Arbeitsmittel entsprechend angepasst werden.

gen. Die folgenden Abschnitte zeigen zu jedem der genannten Gestaltungsfelder (a-e) einzelne Beispiele aus der aktuellen Forschung und geben somit einen praktischen Überblick, wie KI für die Arbeitsgestaltung eingesetzt werden kann.

Gestaltung der Arbeitsaufgabe

Es steht fest, dass „der arbeitende Mensch [...] der wichtigste und wertvollste Produktionsfaktor“ im Arbeitsprozess ist ^[1]. Die Belastung einer Arbeitsaufgabe beinhaltet die Anforderungen, denen der Mensch während der Arbeit ausgesetzt ist. Geistige oder körperliche Überforderung kann Ursache für Erkrankungen und Arbeitsausfälle sein. Eine Anpassung der Arbeitsaufgabe hat Einfluss auf die Gesundheitsförderung des Menschen und somit auch auf das konkrete Ergebnis der Arbeit.

Die Reaktion des Menschen unter Berücksichtigung der individuellen Leistungsvoraussetzungen wird als „Beanspruchung“ bezeichnet (vgl. Belastungs-Beanspruchungs-Modell ^[1]). Das Ziel bei der Gestaltung der Arbeitsaufgabe ist es, die Belastungen zu optimieren und so die Beanspruchung zu reduzieren. KI kann dabei gezielt eingesetzt werden, um die Gefährdung physischer und psychischer Belastung zu analysieren. Für die physische Belastung haben sich Körperhal-

tungsanalysen etabliert ^[2, 3], die durch Bewegungserkennungssysteme flexibel eingesetzt werden können. Ebenso erlaubt KI die Abschätzung muskulärer Belastung ^[4] bei der Durchführung einer Arbeit. Für die Erfassung der psychischen Belastung am Arbeitsplatz eignen sich KI-Systeme zur Sprachmodellierung ^[5], da so die Notwendigkeit einer professionellen Therapie frühzeitig erkannt werden kann ^[6].

Neben der Ermittlung von Belastung am Arbeitsplatz sind auch KI-Lösungen zu finden, die eine Arbeitsaufgabe durch digitale Assistenten unterstützen, bspw. bei der Fehlerdiagnose ^[7], der vorausschauenden Wartung ^[8], Zustandsüberwachung ^[9] oder Qualitätssicherung ^[10]. Die Unterstützung ist dabei bei den konkreten Arbeitsaufgaben, wie z. B. mittels Augmented-Reality-Geräten bei Wartungs- oder Montageprozessen ^[11] bzw. ^[12], aber auch bei der individuellen Zeitplanung zur Optimierung der Work-Life-Balance ^[13] oder zur Motivation einer Arbeitsaufgabe ^[14] möglich.

Interaktionsergonomische Gestaltung

Eine gute Gestaltung der Interaktion zwischen Mensch und Arbeitsmittel ermöglicht einen fehlerarmen Informationsfluss sowie die Reduktion von Störungen, Unfällen und Fehlbeanspruchungen ^[1]. Vor allem visuelle und auditive Signale haben dabei eine große



Bedeutung. Durch KI-Technologien ist eine inhärente Möglichkeit geboten, Informationen für die menschliche Wahrnehmung aufzubereiten. Das gilt für die Visualisierung von Mustern in großen Datensammlungen^[15] oder aus Sensordaten^[16], aber auch für das Verständnis von Modellen^[17], die visuelle Unterstützung bei Prozessanalysen^[18] oder die Generierung von sequenziellen, tabellarischen oder räumlichen Darstellungen^[19]. Für die Bereitstellung akustischer Information in der Interaktion finden sich Einsatzmöglichkeiten von KI in der Filterung von Umgebungsgeräuschen aus Warnsignalen^[20] oder in der Implementierung von Schnittstellen, die vollständige Sätze in natürlicher Sprache generieren können^[21].

Auf der anderen Seite ist KI auch ein hilfreiches Werkzeug, um Befehle an Maschinen zu übermitteln. Aus anthropologischer Perspektive umfasst die Palette der Interaktionsmöglichkeiten im wesentlichen Körperbewegungen - neben der Bedienung von Stellteilen aber auch Gestik oder akustische Sprachbefehle. KI unterstützt dabei eine robuste, flexible und effiziente Informationsaufnahme am Arbeitsmittel. Es können bspw. handelsübliche Kameras verwendet werden, um Finger-, Hand-^[22] oder Ganzkörperverfolgung^[23] zu realisieren, bzw. Systeme konfiguriert werden, die auch unter Einfluss industrietypischer Lärmbelastung eine Spracherkennung ermöglichen^[24].

Auch bei der ergonomischen Gestaltung von konkreten Stellteilen können sich KI-Technologien als nützlich erweisen, da Nutzerverhalten vorhergesagt^[25] und somit beim Design einbezogen oder generative Methoden bei der Gestaltung von Produkten verwendet werden können^[26].

Mit dem Einsatz von KI ist auch eine komplexe Interaktion zwischen dem Menschen und einem Arbeitsmittel möglich, bspw. um mittels „Learning by Demonstration“ bestimmte Arbeitsausführungen an Industrierobotern zu vermitteln^[27], per Chatbot die Fehlersuche an Maschinen zu verbessern^[28], in Armbändern taktile Signale durch Muskelaktivität zu induzieren^[29] oder

durch Objekterkennung mittels VR-Brillen den digitalen Zwilling eines Arbeitsumfeldes zu synchronisieren^[30].

Zur Bewertung der Gebrauchstauglichkeit werden üblicherweise Usability-Tests eingesetzt. Auch hier können KI-Technologien verwendet werden, z. B. in Form eines Software-Frameworks zur Bewertung der Anforderung in cyberphysischen Systemen^[31], mittels KI-basierter kollaborativer Videoanalysen^[32] oder für die Detektion von Emotionen während der Interaktion^[33], wodurch ein subjektives Feedback bei der Nutzung einer Schnittstelle ermöglicht wird.

Anthropometrische und biomechanische Gestaltung

Der Fokus bei der anthropometrischen Gestaltung einer Mensch-Maschine-Schnittstelle liegt auf dem Einbezug von Körpermaßen und biomechanischen Zusammenhängen zur Gestaltung der Arbeitsmittel. Durch die maßliche Gestaltung von Produkten und Arbeitsplätzen wird eine optimierte Funktionalität gewährleistet^[1]. Mit KI-Technologien wird ein Werkzeug geboten, das mit dem großen Spektrum der Verschiedenartigkeit des Menschen effektiv umgehen kann. In kollaborativen Arbeitssystemen, in denen Mensch und Roboter örtlich gemeinsam agieren, kann bspw. durch Vorhersage von Arbeitsbewegung^[34] das Kollisionsrisiko mit Transportrobotern^[35] oder Industrierobotern^[36] reduziert werden. Zur Protokollierung der durchgeführten Tätigkeiten können inertielle Sensoren eingesetzt werden. Die Erkennung menschlicher Tätigkeiten bietet dadurch eine Grundlage zur Optimierung des Arbeitsprozesses^[37].

Viele dieser Funktionen sind in sogenannten digitalen Menschmodellen verfügbar^[38, 39, 40]. In diesen virtuellen Umgebungen können Arbeitsplätze bereits in der Entwurfsphase menschenzentriert bewertet werden, beispielsweise indem für unterschiedliche anthropometrische Eigenschaften die Erreichbarkeit^[41] oder



Sichtbarkeit ^[42] von bestimmten Maschinenelementen bzw. Arbeitsmitteln ermittelt wird. Durch maschinelles Lernen ist es auch möglich, die Kinematik von Körpersegmenten zu synthetisieren. Das ist für die Arbeitswissenschaft insofern dienlich, als dass unterschiedliche potenzielle Bewegungsvariationen oder Stile bei der Ausführung von Tätigkeiten im virtuellen Prototyp analysiert werden können.

Gestaltung der Arbeitsorganisation

Durch das Zusammenwirken mehrerer verschiedener Arbeitssysteme entsteht ein Verbund von hohem Komplexitätsgrad ^[1]. Trotz des heterogenen Verständnisses des Begriffes „Organisation“ kann ein Begriffsschwerpunkt beim Aufbau und der Ablauforganisation inklusive der Arbeitsteilung sowie bei den Rahmenbedingungen zur Arbeitszeit, aber auch bei den konkreten Fragestellungen zur Prozessoptimierung ausgemacht werden. Auch hierbei wird KI als Hilfsmittel eingesetzt, z. B. um die Komplexität zu reduzieren bzw. den Umgang damit zu erleichtern.

Für eine zeitwirtschaftliche Organisation von manuellen Bewegungsabläufen werden bspw. im industriellen Kontext oft sogenannte „Systeme vorbestimmter Zeiten“ verwendet. Das etablierte MTM-System (MTM – Method Time Management) bietet zur Planung einen Katalog mit spezifischen Prozessbausteinen. Durch die Verwendung KI-gestützter Gestenerkennung können solche Elemente automatisch klassifiziert werden, wodurch sich die Einsatzmöglichkeiten der MTM-Methode deutlich erhöht ^[43].

Zur Optimierung und Steuerung von Produktionsprozessen wird häufig das Kanban-System eingesetzt. Das Ziel ist es, dabei durch die zeitliche Organisation von Teilaufgaben den Verbrauch von Ressourcen zu optimieren. KI kann auch eingesetzt werden, um den Workflow mit Kanban zu optimieren ^[44, 45].

Gestaltung der Arbeitsumwelt

Alle äußeren Umgebungsbedingungen, die den menschlichen Körper am Arbeitsplatz beeinflussen, werden in der Arbeitsumweltgestaltung analysiert und bewertet. Die Gestaltung der Arbeitsumwelt hat wiederum enormen Einfluss auf die psychische und physische Belastung, die Arbeitsleistung und Arbeitssicherheit, das Wohlbefinden und die Zufriedenheit der Beschäftigten ^[1].

Mittels KI können viele Umweltfaktoren erkannt werden. Es können so Risiken von Hörschäden bei industriellen Umgebungsgeräuschen vorhergesagt ^[46] oder Warnsysteme realisiert werden ^[47]. Durch Vibrationen an Maschinen ist ebenfalls eine Gefahrenquelle am Arbeitsplatz gegeben, die durch KI-Systeme in Echtzeit erkannt werden kann, wodurch man wiederum entsprechenden Berufskrankheiten vorbeugen kann ^[48]. Zur Vorhersage einer thermophysischen Belastung in industrieller Umgebung können KI-gestützte Detektoren an der Arbeitskleidung eingesetzt werden ^[49] oder durch fusionierte Sensordaten ein Warnsystem für gefährliche Arbeitstemperatur implementiert werden ^[50]. Auch im Umgang mit Gefahrenstoffen wurden durch KI-Technologien bemerkenswerte Fortschritte gemacht. Die frühzeitige Detektion von giftigen Stoffen ^[51] oder Strahlung ^[52] erhöht signifikant die Sicherheit am Arbeitsplatz.

Abschließend sei erwähnt, dass nicht nur zur Warnung vor Risiken, die mit der Arbeitsumwelt verbunden sind, sondern auch zur automatisierten Steuerung von Einflussfaktoren KI eingesetzt werden kann, wie bspw. zur adaptiven Regelung von Lichtverhältnissen ^[53] oder der Temperatur ^[54] am Arbeitsplatz.

Zusammenfassung

KI-Technologien bieten vielseitige Einsatzmöglichkeiten in verschiedenen arbeitswissenschaftlichen Gestaltungsfeldern. Sie verbessern die Interaktion zwischen dem Menschen und der Maschine, optimieren



die Belastung bei Verwendung von Arbeitsmitteln und Erfüllung der Aufgaben, unterstützen die Arbeitsorganisation und tragen zur Gestaltung einer sicheren und ergonomischen Arbeitsumwelt bei.

Durch die intensiven Forschungen und Entwicklungen von KI kann aus einem großen Pool bereits bestehender Lösungen geschöpft werden. Die Ergebnisse sind oftmals individuelle, aber auch adaptive Anwendungen für komplexe Gestaltungszwecke im Arbeitssystem. Methoden des maschinellen Lernens ermöglichen es zudem, auch auf Anforderungen einzugehen, die schwer zu formalisieren sind und daher bislang nicht mit Softwarelösungen automatisiert wurden.

Da neben der Entwicklung der Algorithmen auch eine wachsende Verfügbarkeit geeigneter Trainingsdaten zu beobachten ist, kann davon ausgegangen werden, dass die Palette der KI-Anwendungen für die Arbeitsgestaltung in Zukunft noch facettenreicher ausfallen wird.

Literatur

- [1] M. Schmauder und B. Spanner-Ulmer, „Ergonomie“, in Ergonomie, Carl Hanser Verlag GmbH & Co. KG, 2022, S. 1-12. doi: 10.3139/9783446473584.fm.
- [2] C. Fan, Q. Mei, und X. Li, „3D pose estimation dataset and deep learning-based ergonomic risk assessment in construction“, Autom. Constr., Bd. 164, S. 105452, Aug. 2024, doi: 10.1016/j.autcon.2024.105452.
- [3] X. Li, „A visual ergonomic assessment approach using Kinect and OWAS in real workplace environments“, Multiscale Multidiscip. Model. Exp. Des., Bd. 6, Nr. 1, S. 123-134, März 2023, doi: 10.1007/s41939-022-00133-w.
- [4] S. T. Stanelle, S. F. Crouse, T. R. Heimdahl, S. E. Riechman, A. L. Remy, und B. S. Lambert, „Predicting muscular strength using demographics, skeletal dimensions, and body composition measures“, Sports Med. Health Sci., Bd. 3, Nr. 1, S. 34-39, Feb. 2021, doi: 10.1016/j.smhs.2021.02.001.
- [5] I. Hungerbuehler, K. Daley, K. Cavanagh, H. Garcia Claro, und M. Kapps, „Chatbot-Based Assessment of Employees' Mental Health: Design Process and Pilot Implementation“, JMIR Form. Res., Bd. 5, Nr. 4, S. e21678, Apr. 2021, doi: 10.2196/21678.
- [6] S. Ji, T. Zhang, L. Ansari, J. Fu, P. Tiwari, und E. Cambria, „MentalBERT: Publicly Available Pretrained Language Models for Mental Healthcare“. arXiv, 29. Oktober 2021. Zugegriffen: 28. Juni 2024. [Online]. Verfügbar unter: <http://arxiv.org/abs/2110.15621>
- [7] F. Zhou, S. Yang, H. Fujita, D. Chen, und C. Wen, „Deep learning fault diagnosis method based on global optimization GAN for unbalanced data“, Knowl.-Based Syst., Bd. 187, S. 104837, Jan. 2020, doi: 10.1016/j.knsys.2019.07.008.
- [8] M. Moleda, B. Malysiak-Mrozek, W. Ding, V. Sunderam, und D. Mrozek, „From Corrective to Predictive Maintenance—A Review of Maintenance Approaches for the Power Industry“, Sensors, Bd. 23, Nr. 13, Art. Nr. 13, Jan. 2023, doi: 10.3390/s23135970.
- [9] V. Nasir und F. Sassani, „A review on deep learning in machining and tool monitoring: methods, opportunities, and challenges“, Int. J. Adv. Manuf. Technol., Bd. 115, Nr. 9-10, S. 2683-2709, Aug. 2021, doi: 10.1007/s00170-021-07325-7.
- [10] R. S. Peres, J. Barata, P. Leitao, und G. Garcia, „Multistage Quality Control Using Machine Learning in the Automotive Industry“, IEEE Access, Bd. 7, S. 79908-79916, 2019, doi: 10.1109/ACCESS.2019.2923405.
- [11] J. M. Runji, Y.-J. Lee, und C.-H. Chu, „Systematic Literature Review on Augmented Reality-Based Maintenance Applications in Manufacturing Centered on Operator Needs“, Int. J. Precis. Eng. Manuf.-Green Technol., Bd. 10, Nr. 2, S. 567-585, März 2023, doi: 10.1007/s40684-022-00444-w.
- [12] V. S. Cim und M. D. S. Hounsell, „Augmented Reality for Assembly Training in Industry: A Systematic Literature Mapping“, in Proceedings of the 25th Symposium on Virtual and Augmented Reality, in SVR '23. New York, NY, USA: Association for Computing Machinery, Jan. 2024, S. 77-87. doi: 10.1145/3625008.3625020.
- [13] J. Cranefield, M. Winikoff, Y.-T. Chiu, Y. Li, C. Doyle, und A. Richter, „Partnering with AI: the case of digital productivity assistants“, J. R. Soc. N. Z., Bd. 53, Nr. 1, S. 95-118, Jan. 2023, doi: 10.1080/03036758.2022.2114507.
- [14] A. Oesinghaus, E. Elshan, und H. O. Sandvik, „The Future of Work Unleashed: Generative AI's Role in Shaping Knowledge Workers' Autonomous Motivation“, ECIS 2024 Proc., Juni 2024, [Online]. Verfügbar unter: https://aisel.aisnet.org/ecis2024/track04_impactai/track04_impactai/2
- [15] S. Movva, S. K. Devineni, M. Meitivyeki, A. Tak, und K. Manukonda, „AI-Enhanced Data Visualization: Transforming Complex Data into Actionable Insights.“, 2024, S. 28-61.
- [16] Y. Kim u. a., „SensorViz: Visualizing Sensor Data Across Different Stages of Prototyping Interactive Objects“, in Designing Interactive Systems Conference, Virtual Event Australia: ACM, Juni 2022, S. 987-1001. doi: 10.1145/3532106.3533481.
- [17] B. Kovalerchuk, R. Andonie, N. Datia, K. Nazemi, und E. Banissi, „Visual Knowledge Discovery with Artificial Intelligence: Challenges and Future Directions“. arXiv, 4. Mai 2022. doi: 10.48550/arXiv.2205.01296.
- [18] C. Zhao, „Perspectives on nonstationary process monitoring in the era of industrial artificial intelligence“, J. Process Control, Bd. 116, S. 255-272, Aug. 2022, doi: 10.1016/j.jprocont.2022.06.011.
- [19] Y. Ye u. a., „Generative AI for visualization: State of the art and future directions“, Vis. Inform., Bd. 8, Nr. 2, S. 43-66, Juni 2024, doi: 10.1016/j.visinf.2024.04.003.
- [20] P. Sharma und B. Dash, Using Artificial Intelligence to Filter out Barking, Typing, and other Noise from Video Calls in Microsoft Teams. 2023.
- [21] H. K. Skrodelis, A. Romanovs, N. Zenina, und H. Gorskis, „The Latest in Natural Language Generation: Trends, Tools and Applications in Industry“, in 2023 IEEE 10th Jubilee Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), Vilnius, Lithuania: IEEE, Apr. 2023, S. 1-5. doi: 10.1109/AIEEE58915.2023.10134841.
- [22] J. Gopsill, A. Kukreja, C. M. J. Cox, und C. Snider, „A low-cost non-intrusive spatial hand tracking pipeline for product-process interaction“, Proc. Des. Soc., Bd. 4, S. 2069-2078, Mai 2024, doi: 10.1017/pds.2024.209.
- [23] S. Kreiss, L. Bertoni, und A. Alahi, „OpenPifPaf: Composite Fields for Semantic Keypoint Detection and Spatio-Temporal Association“. arXiv, 21. September 2021. doi: 10.48550/arXiv.2103.02440.
- [24] C. Medina, R. Coelho, und L. Zăo, „Impulsive Noise Detection for Speech Enhancement in HHT Domain“, IEEEACM Trans. Audio Speech Lang. Process., Bd. 29, S. 2244-2253, 2021, doi: 10.1109/TASLP.2021.3093392.
- [25] X. Li, H. Zheng, J. Chen, Y. Zong, und L. Yu, „User Interaction Interface Design and Innovation Based on Artificial Intelligence Technology“, J. Theory Pract. Eng. Sci., Bd. 4, Nr. 03, Art. Nr. 03, März 2024, doi: 10.53469/jtpes.2024.04(03).01.



- [26] M. Ghoreishi und A. Happonen, „New promises AI brings into circular economy accelerated product design: a review on supporting literature“, E3S Web Conf., Bd. 158, S. 06002, 2020, doi: 10.1051/e3sconf/202015806002.
- [27] J. Li, J. Zhong, J. Yang, und C. Yang, „An incremental learning framework to enhance teaching by demonstration based on multimodal sensor fusion“, Front. Neurobotics, Bd. 14, 2020.
- [28] K. S. Kiangala und Z. Wang, „An experimental hybrid customized AI and generative AI chatbot human machine interface to improve a factory troubleshooting downtime in the context of Industry 5.0“, Int. J. Adv. Manuf. Technol., Bd. 132, Nr. 5, S. 2715-2733, Mai 2024, doi: 10.1007/s00170-024-13492-0.
- [29] H. Zhou, C. Tawk, und G. Alici, „A Multipurpose Human-Machine Interface via 3D-Printed Pressure-Based Force Myography“, IEEE Trans. Ind. Inform., Bd. 20, Nr. 6, S. 8838-8849, Juni 2024, doi: 10.1109/TII.2024.3375376.
- [30] Y. M. Tang, W. T. Kuo, und C. K. M. Lee, „Real-time Mixed Reality (MR) and Artificial Intelligence (AI) object recognition integration for digital twin in Industry 4.0“, Internet Things, Bd. 23, S. 100753, Okt. 2023, doi: 10.1016/j.iot.2023.100753.
- [31] S. Gupta, G. Epiphaniou, und C. Maple, „AI-augmented usability evaluation framework for software requirements specification in cyber physical human systems“, Internet Things, Bd. 23, S. 100841, Okt. 2023, doi: 10.1016/j.iot.2023.100841.
- [32] M. Fan, X. Yang, T. Yu, Q. V. Liao, und J. Zhao, „Human-AI Collaboration for UX Evaluation: Effects of Explanation and Synchronization“, Proc ACM Hum-Comput Interact, Bd. 6, Nr. CSCWI, S. 96:1-96:32, Apr. 2022, doi: 10.1145/3512943.
- [33] J. O. Johanssen, J. P. Bernius, und B. Bruegge, „Toward Usability Problem Identification Based on User Emotions Derived from Facial Expressions“, in 2019 IEEE/ACM 4th International Workshop on Emotion Awareness in Software Engineering (SEmotion), Montreal, QC, Canada: IEEE, Mai 2019, S. 1-7, doi: 10.1109/SEmotion.2019.00008.
- [34] K. Lyu, H. Chen, Z. Liu, B. Zhang, und R. Wang, „3D Human Motion Prediction: A Survey“. arXiv, 7. März 2022. doi: 10.48550/arXiv.2203.01593.
- [35] E. Scherstjanoi und S. Wähnert, „Avoidance Of Collisions Through Prospective Path Planning“, gehalten auf der 1st international Conference on Hybrid Societies, Chemnitz, 2023.
- [36] A. Pereira und M. Althoff, „Calculating human reachable occupancy for guaranteed collision-free planning“, in 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Vancouver, BC: IEEE, Sep. 2017, S. 4473-4480. doi: 10.1109/IROS.2017.8206314.
- [37] F. Niemann u. a., „LARA: Creating a Dataset for Human Activity Recognition in Logistics Using Semantic Attributes“, Sensors, Bd. 20, Nr. 15, S. 4083, 2020.
- [38] A. C. Bullinger-Hoffmann und J. Mühlstedt, Homo Sapiens Digitalis - Virtuelle Ergonomie und digitale Menschmodelle. Springer, 2016.
- [39] C. Kamusella, E. Scherstjanoi, und M. Schmauder, „Ergotyping tools for ergonomic research on human-machine interfaces in Digital Prototyping“, Occup. Ergon., Bd. 12, Nr. 3, S. 97-107, 2015, doi: 10.3233/OER-150227.
- [40] S. Scataglini und G. Paul, DHM and Posturography. Academic Press, 2019.
- [41] K. E. Selvan und D. Sen, „Estimating functional reach envelopes for standing postures using digital human model“, Theor. Issues Ergon. Sci., Bd. 21, Nr. 2, S. 153-182, März 2020, doi: 10.1080/1463922X.2019.1666928.
- [42] W. Wu, X. Shao, und H. Liu, „Automatic visibility evaluation method for application in virtual prototyping environment“, Int. J. Comput. Integr. Manuf., Bd. 32, Nr. 10, S. 960-978, Okt. 2019, doi: 10.1080/0951192X.2019.1667027.
- [43] A. Bellarbi, J.-P. Jessel, und L. Da Dalto, „Towards Method Time Measurement Identification Using Virtual Reality and Gesture Recognition“, in 2019 IEEE International Conference on Artificial Intelligence and Virtual Reality (AIVR), Dez. 2019, S. 191-1913. doi: 10.1109/AIVR46125.2019.00040.
- [44] M. Marialuisa, S. Matteo M., und S. Muhammad, „Optimizing milk-run system and IT-based Kanban with artificial intelligence: an empirical study on multi-lines assembly shop floor“, Prod. Manuf. Res., Bd. 11, Nr. 1, S. 2179123, Dez. 2023, doi: 10.1080/21693277.2023.2179123.
- [45] A. Rokoss, L. Popkes, K. Kramer, T. Green, und M. Schmidt, „KI-Kanban-Behälter: Mobile, dezentrale Logistikkatenerfassung mittels Edge-ML“, Z. Für Wirtsch. Fabr., Bd. 118, Nr. 1-2, S. 59-63, Feb. 2023, doi: 10.1515/zwf-2023-1004.
- [46] Y. Zhao u. a., „Machine Learning Models for the Hearing Impairment Prediction in Workers Exposed to Complex Industrial Noise: A Pilot Study“, Ear Hear., Bd. 40, Nr. 3, S. 690, Juni 2019, doi: 10.1097/AUD.0000000000000649.
- [47] M. C. I. Madahana, J. E. D. Ekoru, B. Sebothoma, und K. Khoza-Shangase, „Development of an artificial intelligence based occupational noise induced hearing loss early warning system for mine workers“, Front. Neurosci., Bd. 18, März 2024, doi: 10.3389/fnins.2024.1321357.
- [48] G. Aiello, P. Catania, M. Vallone, und M. Venticinque, „Worker safety in agriculture 4.0: A new approach for mapping operator's vibration risk through Machine Learning activity recognition“, Comput. Electron. Agric., Bd. 193, S. 106637, Feb. 2022, doi: 10.1016/j.compag.2021.106637.
- [49] A. Saidi und C. Gauvin, „Towards real-time thermal stress prediction systems for workers“, J. Therm. Biol., Bd. 113, S. 103405, Apr. 2023, doi: 10.1016/j.jtherbio.2022.103405.
- [50] L. Wang u. a., „A deep learning-based high-temperature overtime working alert system for smart cities with multi-sensor data“, Nondestruct. Test. Eval., Jan. 2024, Zugegriffen: 27. Juni 2024. [Online]. Verfügbar unter: <https://www.tandfonline.com/doi/full/10.1080/10589759.2023.2274008>
- [51] T. Hartung, „Artificial intelligence as the new frontier in chemical risk assessment“, Front. Artif. Intell., Bd. 6, Okt. 2023, doi: 10.3389/frai.2023.1269932.
- [52] G. Liu u. a., „Occupational Health Risk Recognition, Evaluation, and Management of Radiation Workers in Gansu Province, China“, Radiat. Phys. Chem., S. 11981, Juni 2024, doi: 10.1016/j.radphyschem.2024.11981.
- [53] K. Karyono, B. M. Abdullah, A. J. Cotgrave, A. Bras, und J. Cullen, „Human-Centred Approach in Industry 4.0: Lighting Comfort in the Workplace“, in Advances in Manufacturing Processes, Intelligent Methods and Systems in Production Engineering, A. Batako, A. Burduk, K. Karyono, X. Chen, und R. Wyciółkowski, Hrsg., Cham: Springer International Publishing, 2022, S. 533-546. doi: 10.1007/978-3-030-90532-3_40.
- [54] J. Ngarambe, G. Y. Yun, und M. Santamouris, „The use of artificial intelligence (AI) methods in the prediction of thermal comfort in buildings: energy implications of AI-based thermal comfort controls“, Energy Build., Bd. 211, S. 109807, März 2020, doi: 10.1016/j.enbuild.2020.109807.



MetaLearn

ZUSAMMENSPIEL VON MENSCH UND ROBOTIK ZUR STEIGERUNG DER LEBENS- DAUER VON WÄLZSCHÄL- WERKZEUGEN

EIN KI-MODELL ZUR ANOMALIEERKENNUNG AUF BASIS NOMINALER DATEN

Daniel Kiefer (ESB Business School), Florian Grimm (ESB Business School), Jacqueline Höllig (FZI Forschungszentrum Informatik), Tim Straub (ESB Business School), Günter Bitsch (ESB Business School), Clemens van Dinther (KIT)

Durch das Zusammenspiel von Facharbeitern und Algorithmen in der automatisierten Werkzeugwartung kann die Lebensdauer von Wälzschälwerkzeugen verlängert und die Notwendigkeit manueller Inspektionen reduziert werden. Der Einsatz von Algorithmen, die ausschließlich mit nominalen Daten arbeiten, bietet für Industrieunternehmen erhebliche Vorteile, da nominale Daten weitaus häufiger vorkommen als Anomalien.

Diese Forschung ist Teil eines Projekts bei einem führenden deutschen Familienunternehmen für hydrodynamische Getriebe und Anbieter verschiedener Antriebs- und Bremssysteme mit Anwendungen in den Bereichen Energie, Transport und Automotive (im Folgenden als Projektpartner bezeichnet). Der deutsche Mittelstand steht oft vor erheblichen Herausforderungen bei der Einführung von KI, hauptsächlich aufgrund der Komplexität von KI-Technologien und der begrenzten Ressourcen, die diesen Unternehmen zur Verfügung stehen, um mit den schnellen technologischen Fortschritten mitzuhalten ^[1, 2].

Der Projektpartner hat das Zahnrad-Wälzschäl als neue Fertigungstechnologie in seinem Produktionswerk implementiert. Wälzschäl ist ein Fertigungsprozess, bei dem Werkzeug und Werkstück in einem festen Verhältnis zueinander rotieren, um präzise

Bearbeitungen zu ermöglichen. Dieser Prozess ist weniger verbreitet als traditionelles Schleifen, Honen, Schaben und konventionelles Wälzschäl ^[3, 4]. Dies führt dazu, dass Werkzeuge schneller verschleifen, da nur wenige Referenzerfahrungen zur Verfügung stehen. Die Kosten für ein neues Werkzeug betragen etwa 5.000 EUR, im Gegensatz zu Nachschärfkosten von 500 EUR. Derzeit wird das Werkzeug (siehe Abbildung 1), das typischerweise etwa 48 Zähne hat, visuell von Facharbeitenden inspiziert, um festzustellen, ob es nachgeschärft werden muss oder noch für die Produktion geeignet ist. Das Ziel ist es, die Lebensdauer der Werkzeuge zu erhöhen. Die Restnutzungsdauer (RUL, Remaining Useful Life) von Werkzeugen beschreibt die verbleibende Zeit, in der ein Werkzeug noch zuverlässig eingesetzt werden kann, bevor es ausgetauscht oder gewartet werden muss. Sie wird oft durch fortlaufende Überwachung und Analyse der Werkzeugleistung ermittelt. Faktoren wie Verschleiß, Belastung und Einsatzbedingungen beeinflussen die RUL. Eine genaue Vorhersage der Restnutzungsdauer ist entscheidend, um ungeplante Ausfälle zu vermeiden und die Effizienz in der Produktion zu steigern.

Verwandte Literatur

Wälzschäl wurde 1910 von George Adams in London patentiert ^[6], waren aber aufgrund der komplexen Maschinenteknologie wirtschaftlich nicht tragfähig. Erst die fortschreitende Verbesserung der elektri-

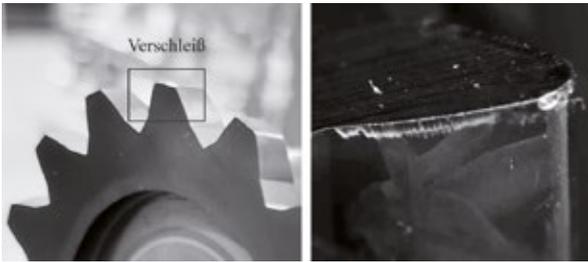


Abbildung 1: Ein Beispiel für den Verschleiß an einem Wälzschäl-Werkzeug

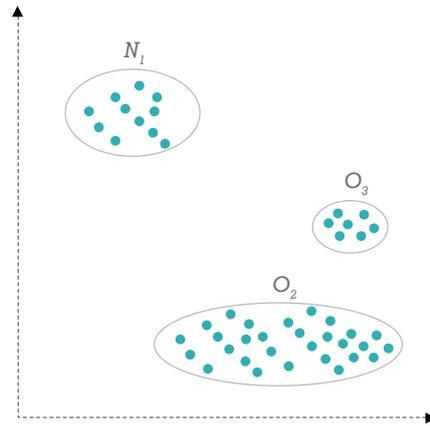


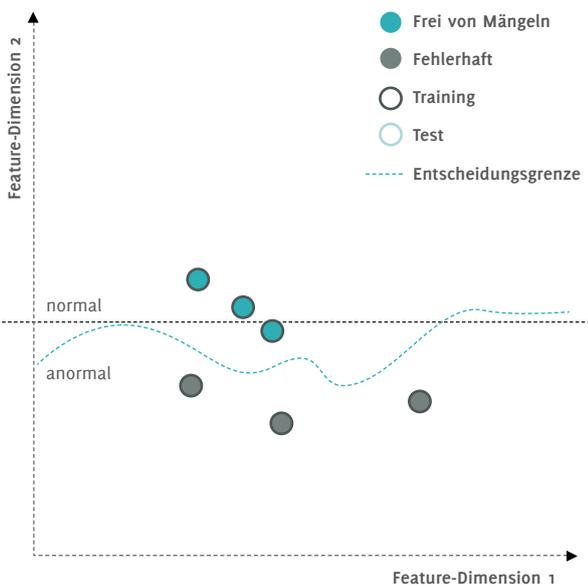
Abbildung 2: Darstellung von Anomalien in einem zweidimensionalen Datensatz

schen Kopplung der Spindeln in jüngster Zeit hat diese Technologie wirtschaftlich umsetzbar gemacht. Beim Wälzschälen entsteht die Schnittgeschwindigkeit dadurch, dass sich Werkstück und Werkzeug mit einer festen hohen Relativgeschwindigkeit zueinander drehen. Gleichzeitig bewegt sich das Werkzeug entlang der Achse des Werkstücks, um den gewünschten Materialabtrag zu erzielen [7].

Die Anomalieerkennung ist der Prozess, bei dem Datenpunkte identifiziert werden, die von den erwarteten Mustern abweichen. Normale Daten entsprechen dabei der Mehrheit der Werte, während anormale Daten Abweichungen darstellen, die im Zusammenhang mit Verschleiß auftreten und die Restnutzungsdauer beeinflussen können [8].

In Bezug auf Lernansätze von Modellen zur Anomalieerkennung unterscheidet man zwischen Modellen, die entweder mit nominalen Daten oder mit Anomalien trainiert werden. Modelle, die mit nominalen Daten arbeiten, lernen die typischen Muster und erkennen Abweichungen als Anomalien. Modelle, die auch mit Anomalien trainiert werden, können sowohl normale als auch fehlerhafte Datenpunkte differenzieren [8]. Der Lernansatz, der sich ausschließlich auf nominale Daten stützt, ist für Industrieanwendungen besonders geeignet, da in vielen industriellen Prozessen Fehler oder Anomalien selten auftreten und schwer zu erfassen sind. Nominale Daten hingegen sind reichlich vorhanden und repräsentieren die normalen Betriebsbedingungen. Durch die Fokussierung auf diese Daten

SZENARIO 1: NUR TRAININGSBILDER



SZENARIO 2: TRAININGS- UND TESTBILDER

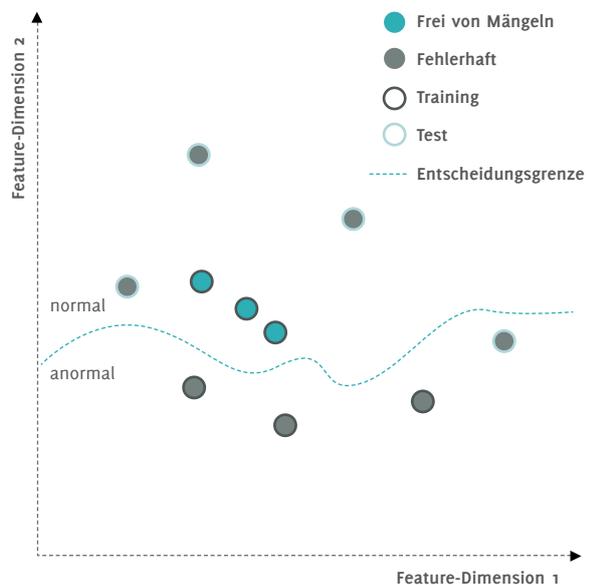
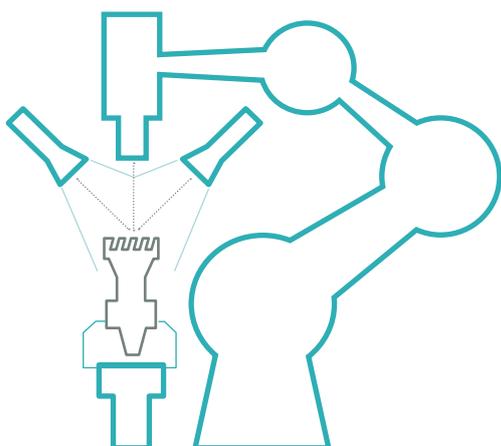
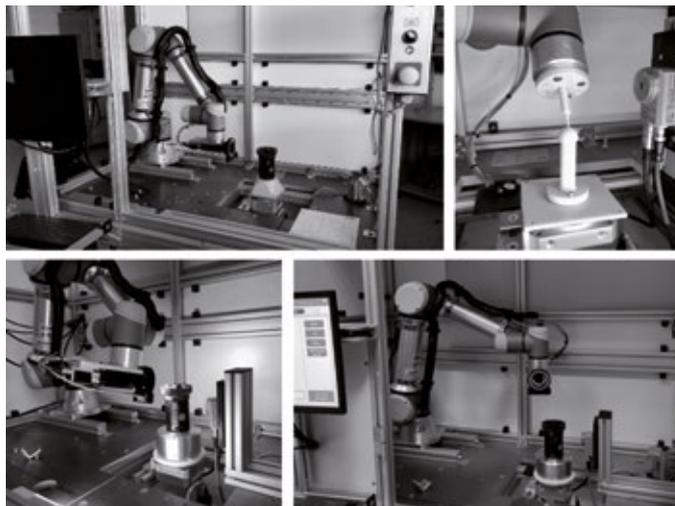


Abbildung 3: Die beiden Abbildungen zeigen einen vereinfachten zweidimensionalen Merkmalsraum eines Modells, das sowohl nominale als auch anomale Lernansätze verfolgt und im Test nicht die erwartete Leistung erbringt



a)



b)

Abbildung 4: Skizze des Messsystems mit einem Gelenkarmroboter zur Kameraführung

können Modelle zuverlässig die Regelzustände lernen und Anomalien als Abweichungen identifizieren. Dies reduziert die Notwendigkeit, große Mengen fehlerhafter Daten zu sammeln, und ermöglicht eine effizientere Überwachung und Vorhersage von Störungen, was die Betriebssicherheit und Produktivität steigert.

Materialien und Methoden

Ein automatisiertes Bilderfassungssystem war erforderlich, um alle relevanten Oberflächen jedes Zahns des Wälzschälwerkzeugs zu erfassen. Dazu gehören die Spanfläche und die drei Freiflächen. Zusätzlich werden zwei weitere Aufnahmen in einem Winkel von 45° auf die Schneidkante zwischen der linken (bzw. rechten) Freifläche und der Spanfläche gemacht.

Aufgrund der hervorragenden Ergebnisse des PatchCore-Algorithmus^[9] im MVTec-Challenge-Datensatz wurde dieser als Haupt-KI-Modell ausgewählt. Er erfüllt die Anforderungen eines nominalen Deep-Learning-Modells, das ausschließlich mit fehlerfreien Bildern trainiert wird.

Der unsupervised nominale Klassifikator wurde mit 84 Bildern intakter Wälzschälwerkzeuge trainiert und anschließend mit 30 Bildern von verschleißbedingten Defekten evaluiert. Im Gegensatz dazu wurde der zweite supervised Ansatz sowohl mit 84 nominalen Bildern als auch mit 268 defekten Beispielen trainiert und ebenfalls auf 30 verschleißdefekten Bildern getestet.

Ergebnisse

Zur Bewertung nutzen wir den AUROC, die Accuracy und den F1-Score. Der AUROC (Area Under the Receiver Operating Characteristic Curve) misst die Fähigkeit eines Modells, zwischen Klassen zu unterscheiden, indem er die Fläche unter der ROC-Kurve darstellt, die das Verhältnis von True Positive Rate (Empfindlichkeit) zu False Positive Rate über verschiedene Schwellenwerte hinweg abbildet. Accuracy gibt den Anteil der korrekt klassifizierten Datenpunkte an der Gesamtzahl der Datenpunkte an und misst somit die allgemeine Modellgenauigkeit. Der F1-Score ist das harmonische Mittel aus Präzision und Recall und dient als genaueres Maß, insbesondere bei unausgeglichene Klassen, da er sowohl falsch positive als auch falsch negative Vorhersagen berücksichtigt.

	PatchCore	AlexNet – pretrained	AlexNet – no pretraining	SVM
AUROC	0.85	0.66	0.48	0.59
Accuracy	0.88	0.70	0.07	0.86
F1	0.93	0.83	0.00	0.92

Tabelle 1: Experiment 1, Klassifikation – nominales Training mit 84 fehlerfreien Bildern

	PatchCore	AlexNet – pretrained	AlexNet – no pretraining	SVM
AUROC	0.85	0.83	0.81	0.64
Accuracy	0.88	0.71	0.58	0.69
F1	0.93	0.83	0.61	0.78

Tabelle 2: Experiment 2, Klassifikation – nominales & anomales Training mit 84 fehlerfreien Bildern und 268 fehlerhaften Bildern. Hinweis: PatchCore weiterhin generativ nur mit 84 fehlerfreien Bildern trainiert.

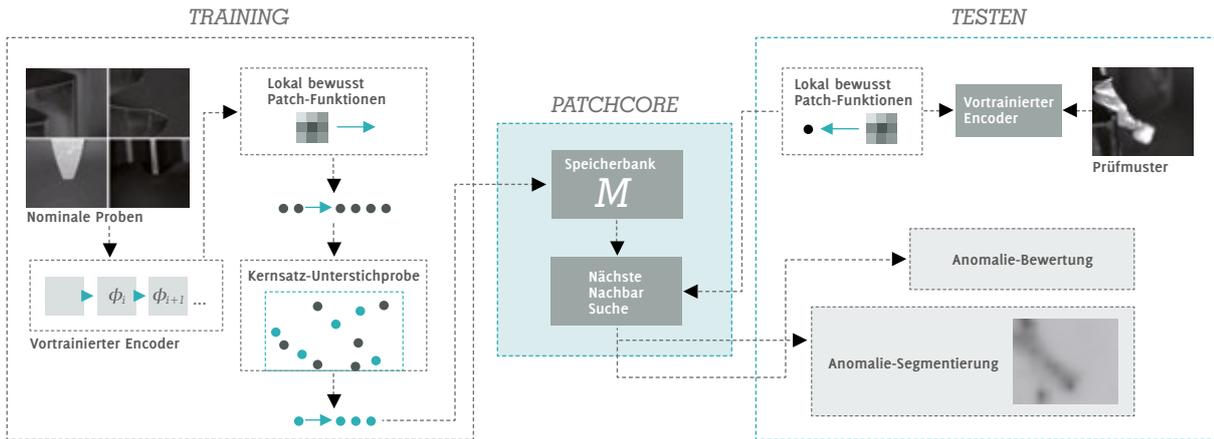


Abbildung 5: PatchCore-Algorithmus

In Experiment 1 (siehe Tabelle 1) wurden die Modelle ausschließlich auf nominaler Basis mit 84 fehlerfreien Bildern trainiert. PatchCore (siehe Abbildung 5) erwies sich als Spitzenreiter mit einem AUROC von 0,85, einer Genauigkeit von 0,88 und einem F1-Score von 0,93, was auf eine ausgezeichnete Balance zwischen Präzision und Recall hinweist.

In Experiment 2 (siehe Tabelle 2) wurde ein Anomalie-Lernansatz eingeführt, bei dem zusätzlich zu den 84 fehlerfreien Bildern 268 defekte Bilder verwendet wurden, um alle Modelle außer PatchCore zu trainieren, das weiterhin ausschließlich mit fehlerfreien Bildern trainiert wurde.

Links sehen wir das Bild, das als Input für das Modell zur Bewertung dient. In der Mitte sind die Bildpixel dargestellt, wobei die als Anomalie eingestufteten Pixel hervorgehoben werden. Rechts zeigt das Bild die Pixel, die als stark anomal eingestuft wurden und den festgelegten Schwellenwert erreicht haben. Diese Pixel werden mit der Ground Truth im Testdatensatz verglichen, um verschiedene Evaluations- und Bewertungsmetriken zu berechnen.

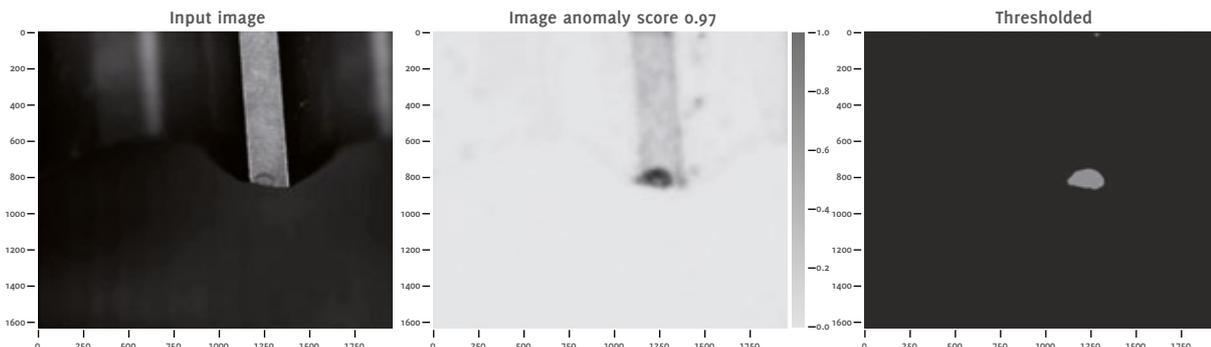


Abbildung 6: Beispiel aus dem industriellen Fertigungsdatensatz mit Klassifikation. Vorderansicht. Bildanomaliewert 0,97. Wahres Positiv, da es sich um einen Ausbruch am Wälzschälwerkzeug handelt.

Implikationen für Praktiker

Basierend auf unseren Erfahrungen in diesem industriellen Anwendungsfall zur Anomalieerkennung haben wir eine Reihe von Schritten identifiziert, die für industrielle Anwender von großem Nutzen sein können. Es zeigt sich, dass KI bereits erfolgreich in industriellen Anwendungen eingesetzt wird und wertvolle Verbesserungen sowie Unterstützung bietet. Die Schritte und Vorgehensweise sind in Abbildung 6 veranschaulicht.

Diskussion und weitere Forschung

Diese Arbeit hat sowohl einen Ansatz zur Klassifizierung von Werkzeugtypen als auch einen Ansatz zur Erkennung von Werkzeugverschleiß bei Schneidwerkzeugen vorgestellt. Unsere Ergebnisse zeigen, dass nominale Modelle, die ausschließlich mit normalen (fehlerfreien) Daten trainiert wurden, traditionelle

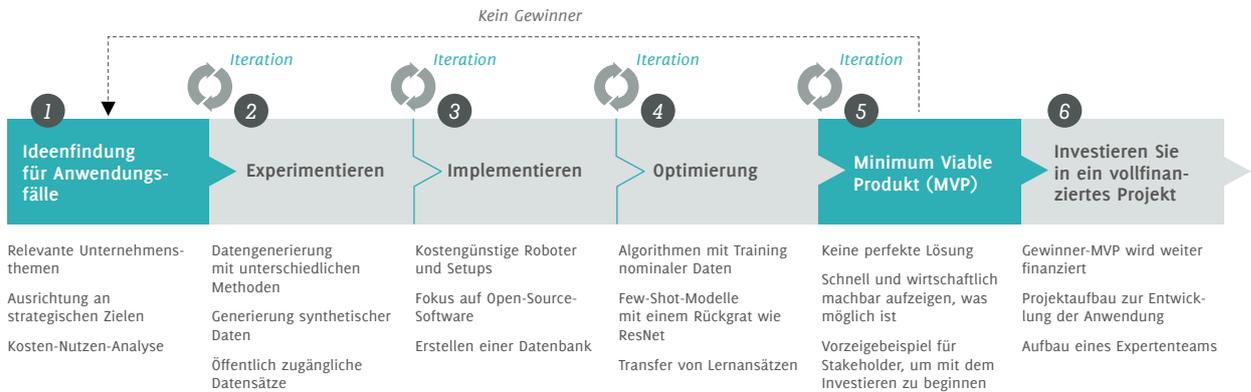


Abbildung 6: Schritte zur erfolgreichen Umsetzung eines KI-Projekts für Praktiker

anomale Lernansätze in der Klassifizierung von Anomalien und der Segmentierung von Verschleiß an Wälzschälwerkzeugen übertreffen können.

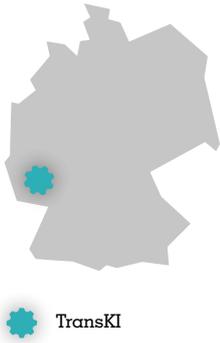
Zukünftige Forschung könnte die Integration von Maschinendaten, wie etwa Achsendrehmoment, Achsengeschwindigkeit, Vibrationen und Achsvorschubgeschwindigkeit, weiter vorantreiben, um fundiertere und präzisere Entscheidungen zu ermöglichen. Diese Daten könnten helfen, den Zustand von Werkzeugen besser vorherzusagen und Wartungsprozesse zu optimieren. Gleichzeitig wird die Akzeptanz solcher Technologien durch die Mitarbeitenden immer wichtiger. Hier setzt die Entwicklung von Frameworks für erklärbare Künstliche Intelligenz (XAI) an, die die Entscheidungsprozesse der KI transparent und nachvollziehbar machen. Ein solches Framework könnte das Vertrauen der Mitarbeitenden stärken, indem es ihnen ermöglicht, die Entscheidungen der KI zu verstehen und aktiv in den Prozess einzugreifen, wodurch eine kooperative Mensch-Maschine-Interaktion gefördert wird.

Die Integration solcher Technologien in industrielle Prozesse birgt sowohl Chancen als auch Herausforderungen für Mitarbeitende. Einerseits können automatisierte Systeme und KI-Modelle, die auf nominalen Daten basieren, die Effizienz steigern, manuelle Inspektionen reduzieren und die Arbeitsbelastung verringern. Andererseits können Mitarbeitende den Eindruck gewinnen, dass ihre Expertise und Entscheidungen durch Maschinen ersetzt werden. Daher ist die Akzeptanz dieser Technologien von entscheidender

Bedeutung. Erklärbare Künstliche Intelligenz (XAI) könnte hier eine Schlüsselrolle spielen, indem sie den Mitarbeitenden ermöglicht, die Entscheidungen der KI nachzuvollziehen und Vertrauen in die Systeme aufzubauen. Ein transparentes Verständnis der KI-Entscheidungen könnte die Zusammenarbeit zwischen Mensch und Maschine verbessern und die Akzeptanz technologischer Innovationen in der Arbeitswelt nachhaltig fördern.

Literatur

- [1] Zamani, S.Z., 2022. Small and Medium Enterprises (SMEs) facing an evolving technological era: A systematic literature review on the adoption of technologies in SMEs.
- [2] Kiefer, D., van Dinther, C., and Straub, T., 2022. The Time has Come - Application of Artificial Intelligence in Small- and Medium-Sized Enterprises, in p. 1.
- [3] Spur, G., Eversheim, W., Sahm, P.R., Michaeli, W. et al., 1999. Produktionstechnologie, in Produktion und management 3, Springer, [S.I.], p. 247.
- [4] Nagata, E., Tachikawa, T., Nakahara, Y., Kurita, N. et al., 2017. Gear skiving for mass production, p.2.
- [5] Antoniadis, A., Vidakis, N., Bilalis, N., 2004. A simulation model of gear skiving 146, p.213.
- [6] Adams, G. Method of cutting van gears using a gear-like cutting tool with cutting edges on the face surfaces of the teeth B23F5/163, 1910(DE243514C). <https://patents.google.com/patent/DE243514C/en>. Accessed 12 February 2024.
- [7] Tsai, C.-Y., 2016. Mathematical model for design and analysis of skiving tool for involute gear cutting 101, p.195.
- [8] Wei, Q., Shi, B., Lo, J.Y., Carin, L. et al., 2018 - 2018. Anomaly detection for medical images based on a one-class classification, in Medical Imaging 2018: Computer-Aided Diagnosis, SPIE, p. 57.
- [9] Bergmann, P., Batzner, K., Fauser, M., Sattlegger, D. et al., 2021. The MVTec Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection 129, p.1038.



TransKI

VON DER MASCHINE BIS ZUR AKTION

INTEGRATION EINER MACHINE-LEARNING- BASIERTEN WERKZEUGÜBERWACHUNG IN EIN ASSISTENZSYSTEM

Peter M. Simon, Maximilian Berndt, Prof. Dr.-Ing. Jan C. Aurich (Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau, Lehrstuhl für Fertigungstechnik und Betriebsorganisation), Jens Henninger (Empolis Information Management GmbH)

Um eine Machine-Learning-basierte Werkzeugüberwachung industriell nutzbar zu machen, muss die Akzeptanz beim Maschinenbediener sichergestellt werden

Das Verschleißverhalten von Zerspanungswerkzeugen kann auch unter konstanten Prozessrandbedingungen signifikant variieren und so die effektive Standzeit maßgeblich beeinflussen ^[1]. Aus diesem Grund werden Zerspanungswerkzeuge in der industriellen Praxis häufig nach definierten Standwegen und damit meist deutlich zu früh getauscht, um Werkzeugversagen zu vermeiden und einen stabilen Prozess zu gewährleisten ^[2]. Aus dem so verschwendeten Standzeitpotential der Werkzeuge resultieren höhere Rüstzeiten und erhöhte Werkzeugkosten. Ansätze zum Tool Condition Monitoring (TCM) versuchen diesem Umstand durch eine kontinuierliche Überwachung des Werkzeugzustands zu begegnen.

Insbesondere Methoden des Machine Learnings (ML) weisen großes Potenzial auf, eine effektive Überwachung des Zerspanprozesses sicherzustellen und eine Ausnutzung der individuellen Standzeit des einzelnen Werkzeugs zu ermöglichen ^[3]. Zur breiten Nutzarmachung einer ML-basierten Werkzeugüberwachung genügt die Entwicklung leistungsfähiger ML-Modelle jedoch nicht, vielmehr müssen die durch die Modelle generierten Informationen und Empfehlungen in einer für den Maschinenbediener geeigneten Weise

aufbereitet und dargestellt werden. Eine Möglichkeit, den Maschinenbediener bestmöglich bei der Wahl des Zeitpunkts für den Werkzeugwechsel zu unterstützen, stellt die Integration performanter ML-Modelle in ein Assistenzsystem dar. Dieser Beitrag beschäftigt sich daher damit, wie eine ML-basierte Werkzeugüberwachung in ein Assistenzsystem integriert werden kann, das den Anforderungen der Maschinenbediener an ein solches System gerecht wird.

Entwicklung der ML-Modelle

Um das Standzeitpotential der Werkzeuge besser zu nutzen, wird im Rahmen des TransKI-Projekts in enger Zusammenarbeit von Industrie und Forschung ein ML-basiertes Assistenzsystem mit dem Fokus auf Bohroperationen entwickelt. Da es sich bei ML-basierten TCM-Systemen um komplexe Systeme mit ineinandergreifenden Schlüsselkomponenten handelt, sind bei der Einrichtung, der Wartung und dem Betrieb mehrere Wissensdomänen beteiligt. Um solche Systeme zu entwickeln, müssen folgende Schritte - ggf. iterativ - unter ständiger Zusammenarbeit der Domänen Datenwissenschaft und Zerspanung durchgeführt werden:

- (1) Einbringen von Domänenwissen über relevante, aber leicht nachrüstbare Sensoren und deren Einbau in Werkzeugmaschinen
- (2) Datenerfassung und -aufbereitung



- (3) Datenübertragung an eine zentrale Instanz (lokal oder als Service)
- (4) Datenbereinigung und Feature Engineering
- (5) Training, Test und Deployment von ML-Algorithmen
- (6) Rückmeldung an den Betreiber oder das Steuerungssystem.

Während die Ansätze für ML-basiertes TCM in der Zerspanung vielfältig sind und viele davon grundsätzlich geeignet sind, werden für die Implementierung Ansätze ausgewählt, die dem Kunden einen hohen zusätzlichen Nutzen bieten können. Um das Potenzial von verschwendeten Werkzeugstandzeiten zu nutzen, werden zwei Ansätze verfolgt, die den Maschinenbediener bei der Auswahl des richtigen Zeitpunkts für den Werkzeugwechsel unterstützen und den Kern des ML-basierten Assistenzsystems bilden:

- Modell zur Erkennung von Anomalien
- Modell für die Bewertung des Remaining Useful Life (RUL) des Zerspanungswerkzeugs

Anomalieerkennung: Ein Ansatz zur Erkennung von Anomalien erweist sich als zielführend, da er Abweichungen von normalen Betriebsmustern identifiziert, die oft auf Werkzeugverschleiß, Unregelmäßigkeiten oder Störungen im Prozess oder ein bevorstehendes Werkzeugversagen hinweisen. Mithilfe der Anomalieerkennung kann das System den Zustand der Werkzeuge während des Bohrvorgangs effektiv überwachen und Anomalien erkennen, die auf einen instabilen Prozess, wie z. B. einen Werkzeugausbruch oder einen erhöhten Werkzeugverschleiß zurückgeführt werden können. Anomalien treten tendenziell häufiger auf, wenn sich das Werkzeug seiner Verschleißgrenze nähert. Für die Anomalieerkennung werden unterschiedliche Algorithmen genutzt, unter anderem XGBoost oder Autoencoder.

RUL-Bewertung: Die RUL-Bewertung für Bohrwerkzeuge bezieht sich auf einen Wert von 100 % bis 0 %, der die geschätzte verbleibende Zeit oder Nutzung

widerspiegelt, bevor das Werkzeug die Anforderungen an die Bearbeitungsqualität nicht mehr erfüllen kann oder ausfällt. Durch das Verständnis der Verschleiß- und Degradationsmuster in den Daten, auf denen der Algorithmus trainiert wurde, können RUL-Modelle vorhersagen, wann ein Werkzeug das Ende seiner effektiven Lebensdauer erreicht. Für die Implementierung werden verschiedene Ansätze genutzt, wie z. B. XGBoost, neuronale Feed-Forward-Netze oder Convolutional Neural Networks mit einer Reihe von Vorverarbeitungsschritten (Umwandlung der Daten in Merkmalsvektoren oder zeitfensterbasierte Eingangsdaten).

Die Entwicklung der Modelle erfordert eine Datenbasis, die aus Standzeitversuchen mit verschiedenen Prozessparametern für unterschiedliche Werkzeugtypen besteht. Als Datenquelle für das als Assistenzsystem implementierte TCM-System dienen sowohl Daten aus der Steuerung der Maschine selbst als auch nachgerüstete Stromwandler zur Messung der Achsströme, die während der Standzeitversuche erfasst werden. Somit kann eine verhältnismäßig aufwandsarme und minimalinvasive Methode zur Datenerhebung sichergestellt werden, die zusätzlich keinen Einfluss auf den Zerspanprozess hat, da kein Eingriff in den Bearbeitungsraum notwendig ist und der Prozess nicht beeinflusst wird.

Funktionsweise des Systems

Die Funktionsweise des Assistenzsystems unter Betriebsbedingungen ist in Abbildung 1 dargestellt. Während des Bohrprozesses werden prozessrelevante Daten erfasst, wofür sich Achs- und Spindelströme oder Leistungsmessungen der Werkzeugmaschine eignen. Die Daten können direkt von der Steuerung oder über die nachgerüsteten Sensoren gewonnen werden, um auch ältere Maschinen überwachen zu können. Die lokal erfassten Daten werden vorverarbeitet (z. B. Downsampling und Konvertierung) und dann über das

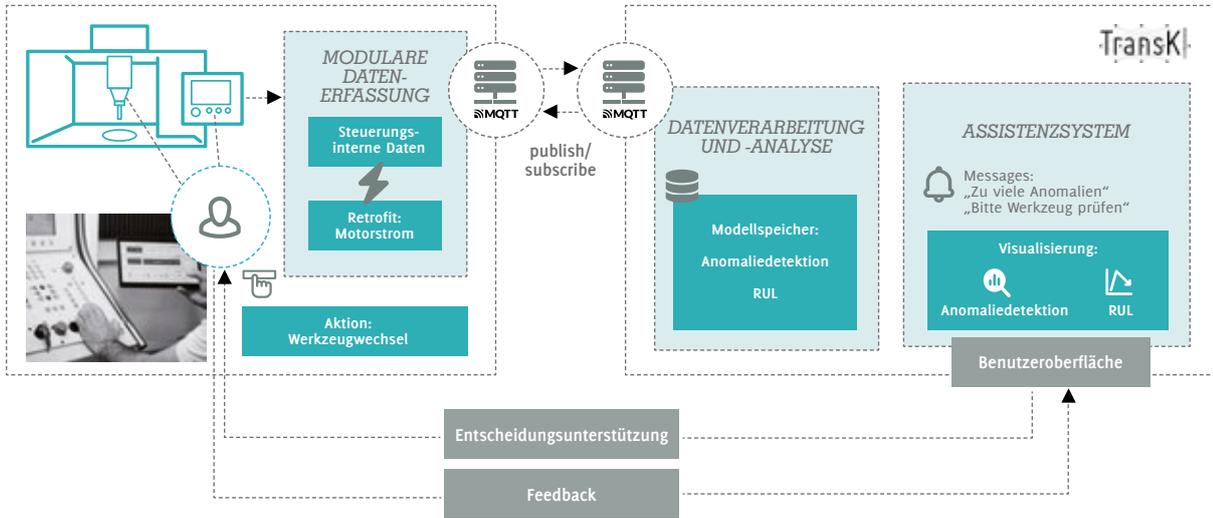


Abbildung 1 Funktionalität des Assistenzsystems

Netzwerkprotokoll MQTT (Message Queuing Telemetry Transport) mithilfe von Datenkonnektoren, die z. B. mit Edge-Computing-Geräten realisiert werden können, an die übergeordnete Computingarchitektur übertragen. Dabei ist zu beachten, dass nur die Daten des zu überwachenden Prozesses übertragen werden, z. B. durch Erweiterung des NC-Codes zum Senden von Triggersignalen für die Messung und Aufzeichnung der Signale. Zusätzlich zu den Prozessdaten werden Metadaten (z. B. Werkzeug-ID, Prozessparameter, Maschinen-ID) zur eindeutigen Identifizierung des Werkzeugs und des Prozesses übertragen. Die Prozessdaten werden in Kombination mit den Metadaten auf einem Server temporär gespeichert und weiterverarbeitet. Nach einer weiteren Datenvorverarbeitung werden die trainierten ML-Modelle auf die Daten angewandt und als Ergebnis werden der Status der Anomalieerkennung und ein Wert für die RUL ermittelt. Es sind mehrere ML-Modelle im Modellspeicher hinterlegt, die für den jeweiligen Anwendungsfall entwickelt wurden. Auf Basis der übermittelten Metadaten kann das passende Modell ausgewählt werden. Die Ergebnisse der Anomalieerkennung sowie des RUL-Modells können in Bezug auf den aktuellen Prozess logisch verknüpft werden, woraus dann konkrete Handlungsempfehlungen (Werkzeugwechsel, Qualitätsprüfung) abgeleitet werden können. Die so generierten Handlungsempfehlungen werden dem Maschinenbediener über eine

Nutzeroberfläche bereitgestellt, die diesem zusätzlich die Möglichkeit bietet, mit dem System zu interagieren.

Um den Anforderungen der Maschinenbediener, also der Menschen, die das Assistenzsystem nutzen sollen, gerecht zu werden, werden Repräsentanten dieser Nutzergruppe frühzeitig in den Entwicklungsprozess eingebunden. Die Entwicklung des TransKI-Assistenzsystems erfolgt nutzerzentriert und orientiert sich am nutzerzentrierten Entwicklungsprozess nach DIN ISO 9241-210. Hierfür werden die folgenden menschzentrierten Gestaltungsaktivitäten teils iterativ durchlaufen: (1) Nutzungskontext analysieren und beschreiben, (2) Nutzungsanforderungen spezifizieren, (3) Gestaltungslösungen entwerfen und (4) Gestaltungslösungen evaluieren. Als besonders zielführend während des nutzerzentrierten Entwicklungsprozesses erweisen sich ein Workshop mit den Projektpartnern, Vor-Ort-Beobachtungen und Interviews von Maschinenbedienern aus der Einzel- und Serienfertigung zur Erfassung der Nutzungsanforderungen. Des Weiteren handelt es sich bei frühzeitigen Evaluationen von Klick-Prototypen und Usability-Tests durch die anvisierten Nutzergruppen um geeignete Instrumente, die adäquate Umsetzung der Anforderungen während des Entwicklungsprozesses sicherzustellen.



Das Ergebnis des Entwicklungsprozesses ist ein prototypisches Assistenzsystem, das den Maschinenbediener bei der Wahl des Zeitpunkts für den Werkzeugwechsel unterstützt. Der Maschinenbediener interagiert mit dem System über eine plattformunabhängige, webbasierte Benutzeroberfläche. Somit ist die Nutzung des Assistenzsystems auf diversen Endgeräten (IPC, Tablet etc.) möglich. Abbildung 2 illustriert die Informationsdarstellung auf der Übersichtsseite des Assistenzsystems. Neben der Navigationsleiste auf der linken Seite sind dort mittig Informationen über den aktuellen Prozess und das aktuell verwendete Werkzeug aufgeführt. Die Ergebnisse der Anomalieerkennung und der RUL-Bewertung werden aufbereitet und dem Maschinenbediener in Form von Visualisierungen und Meldungen verständlich präsentiert. Die durch die RUL-Bewertung gewonnene verbleibende Standzeit wird als Prozentangabe in einem Balken veranschaulicht. Daneben wird die Anzahl der erkannten Anomalien aufgeführt. Beide Anzeigen werden abhängig vom Status des Werkzeugs in den Signalfarben des Ampelsystems eingefärbt. Abhängig von der Anzahl der aufgetretenen Anomalien und der prognostizierten RUL empfiehlt das System den Zeitpunkt für einen Werkzeugwechsel. Diese Meldungen werden in Form von erscheinenden Dialogfenstern dargestellt, damit die Aufmerksamkeit des Nutzers auf diese Meldung fokussiert wird. Der Werkzeugwechsel selbst muss vom Maschinenbediener initiiert und durchgeführt werden. Das System hat keine direkte Verbindung zur Maschine und kann nicht direkt mit dem Prozess interagieren. Über die Benutzerschnittstelle kann der Bediener dem System Rückmeldungen zu den Empfehlungen geben, die für eine kontinuierliche Modellbewertung und weitere Modellentwicklung genutzt werden können.

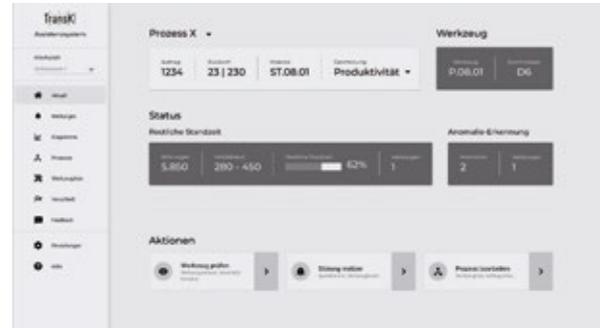


Abbildung 2 Darstellung in der Benutzeroberfläche

Zusammenfassung und Ausblick

Die Entwicklung innerhalb des TransKI-Projekts zeigt, wie eine ML-basierte Werkzeugüberwachung, basierend auf einer Anomalieerkennung und RUL-Bewertung, in ein Assistenzsystem integriert werden kann. Durch den nutzerorientierten Entwicklungsprozess wird sichergestellt, dass das Assistenzsystem den Anforderungen der späteren Nutzerschaft gerecht wird. Die prototypische Umsetzung kann nun in der industriellen Anwendung validiert und optimiert werden. Nach dem erfolgreichen Einsatz für den primär adressierten Bohrprozess kann das Assistenzsystem zukünftig für weitere Prozess wie z. B. das Fräsen und Drehen weiterentwickelt werden.

Literatur:

- [1] K. Salonitis, A. Kolios, Reliability assessment of cutting tool life based on surrogate approximation methods, *The Int. J. of Advanced Manufacturing Technology* 71 (2014) 1197-1208. doi:10.1007/s00170-013-5560-2
- [2] Wiklund, H., 1998. Bayesian and regression approaches to on-line prediction of residual tool life. *Quality and Reliability Engineering International* 14, 303-309, DOI: 10.1002/(SICI)1099-1638(199809/10)14:5%3C303:AID-QRE155%3E3.0.CO;2-F.
- [3] R. Teti, D. Mourtzis, D. D'Addona, A. Caggiano, Process monitoring of machining, *CIRP Ann.* 71 (2) (2022) 529-552. doi:10.1016/j.cirp.2022.05.009.

**UM DEN ANFORDERUNGEN
DER MASCHINENBEDIENER,
ALSO DER MENSCHEN, DIE
DAS ASSISTENZSYSTEM
NUTZEN SOLLEN, GERECHT
ZU WERDEN, WERDEN
REPRÄSENTANTEN DIESER
NUTZERGRUPPE FRÜHZEITIG
IN DEN ENTWICKLUNGS-
PROZESS EINGEBUNDEN.**

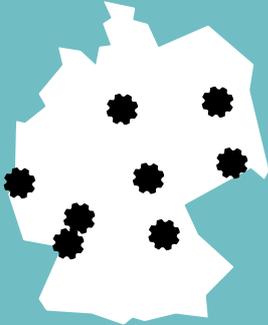




PROJEKTSHECKBRIEFE



1 ProKI



FAKTEN

PROJEKT

Demonstrations- und Transfernetzwerk
ProKI-Netz

STANDORTE

- 📍 **Aachen**
Koordinierungsstelle
- 📍 **Berlin**
- 📍 **Darmstadt**
- 📍 **Dresden**
- 📍 **Hannover**
- 📍 **Ilmenau**
- 📍 **Karlsruhe**
- 📍 **Nürnberg**

Algorithmen der Künstlichen Intelligenz wird ein disruptiver Charakter zugeschrieben, der die Wettbewerbsfähigkeit von Unternehmen signifikant beeinflussen kann. Folglich birgt diese Technologie einerseits das Risiko, dass deutsche Unternehmen an Wettbewerbsfähigkeit verlieren, wenn Sie KI nicht einsetzen, und andererseits das Potenzial sich Wettbewerbsvorteile zu erarbeiten, wenn dieser Einsatz wirtschaftlich und strategisch erfolgt. In der Forschung existieren in Deutschland bereits vielfältige KI-Lösungen für das produzierende Gewerbe. An vielen Hochschulen wird bereits erfolgreich nachgewiesen, dass KI Mehrwerte wie gestiegene Produktivität, Qualität oder Maschinenverfügbarkeit bieten kann.

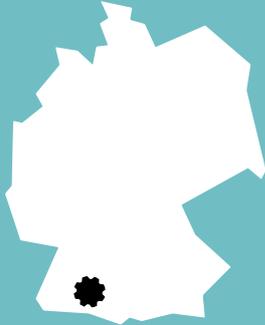
Dennoch erfolgt der Transfer in die Wirtschaft - wo der Wettbewerbsvorteil erst erwirtschaftet wird - noch zu langsam, sodass aktuell nur sehr wenige Unternehmen KI einsetzen, obwohl die Potenziale durchaus erkannt werden. Dieser Herausforderung stellt sich das „Demonstrations- und Transfernetzwerk ProKI“, ein Verbund aus insgesamt acht Hochschulstandorten, verteilt in ganz Deutschland. Durch Demonstrationsmaßnahmen wie Messebesuche oder Hallenführungen werden Unternehmen auf die neuesten Trends und ihre Mehrwerte hingewiesen. Mithilfe von Qualifizierungsmaßnahmen wie Workshops und Seminaren werden Mitarbeitende für den KI-Einsatz geschult und in Transferprojekten werden Unternehmen bei aktuellen Herausforderungen in Sachen KI beraten.

In den vergangenen zwei Jahren wurden durch das ProKI-Netz viele Maßnahmen erfolgreich durchgeführt. Hierzu zählen neben den Großveranstaltungen wie der EMO2023, der Hannover Messe 2024 oder den ProKI-Tagungen auch die vielen Seminare und Workshops über alle Standorte hinweg. Weiterhin ist dieser Projektatlas mit seinem Leitfaden zur Einführung von KI ein großer Meilenstein für das Projekt. In vielen Transferprojekten wurden bereits gemeinsam mit den Unternehmen vielfältige Lösungen entwickelt - ein Trend, der auch nach der Förderperiode fortgeführt werden soll. Für diese Phase wird standortübergreifend eine Verstetigungsstrategie entwickelt, welche die etablierten Maßnahmen auch nach der Förderung erhalten soll.





2 AICoM



FAKTEN

PROJEKT

Lernende Werkzeugmaschine zur autonomen Fräsfertigung kundenindividueller Werkstücke

KOORDINATOR

Gühring KG

PARTNER

- Gühring KG, Albstadt**
Aufbau des Wissensspeichers und Gestaltung der HMI
- Industrielle Steuerungstechnik GmbH, Stuttgart**
Entwicklung eines KI-Modells zur Optimierung von NC-Programmen
- ModuleWorks GmbH, Aachen**
Entwicklung eines CAM-Systems zur KI-unterstützten NC-Programmerstellung
- Synop-Systems UG, Holzgerlingen**
Entwicklung einer Prozessüberwachung für die Vorhersage von Prozessstabilität und Bauteilqualität auf Basis von Bearbeitungsfeatures
- Lorenz Hoffmann GmbH, Kreßberg-Oberstelshausen**
Inbetriebnahme und Evaluation der prototypischen selbstlernenden Werkzeugmaschine
- TU Darmstadt, Institut für Produktionsmanagement, Technologie und Werkzeugmaschinen (PTW), Darmstadt**
Maschinendatenerfassung und Entwicklung des Daten-Preprocessing
- TU Darmstadt, Data Management, Darmstadt**
Entwicklung der Künstlichen Intelligenz (KI) und AutoML-Algorithmen

KMUs im Bereich der Einzelteil- und Kleinserienfertigung sehen sich mit steigenden Kundenanforderungen bzgl. Lieferzeit und hoher Qualität konfrontiert. Um unter diesen Rahmenbedingungen die internationale Wettbewerbsfähigkeit deutscher KMUs zu sichern, werden klassische Vorgehensweisen beim Einsatz moderner Werkzeugmaschinen zur Zerspanung nicht ausreichen. Klassischerweise wird für die Fertigung auf das technologische Verständnis sowie die Erfahrung der Maschinenbediener zurückgegriffen wird. Die Bediener können allerdings aufgrund der geringen Stückzahlen in der Einzelteil- und Kleinserienfertigung kein produktspezifisches Wissen, z. B. durch Optimierungsversuche, aufbauen. Daher werden diese Produkte häufig mit konservativen Prozessparametern gefertigt, die weit unterhalb des Produktivitätsoptimums liegen.

Das Ziel des Forschungsvorhabens AICoM ist die prototypische Entwicklung einer „lernenden Werkzeugmaschine“ am Beispiel des Zerspanungsprozess „Fräsen“, bei der die NC-Programmerstellung durch verschiedene KI-Modelle unterstützt wird, um deren technologischen Prozessparameter hinsichtlich Qualität und Bearbeitungszeit vorab zu optimieren, und bei der der Bearbeitungsprozess selbst durch ein KI-Modell überwacht und bewertet wird. Zur Verringerung des Aufwands des Wissenserwerbs, z. B. durch Versuche, sollen Methoden zum maschinellen Lernen eingesetzt werden. Die erzielten Ergebnisse werden mit einem Demonstrator verifiziert.

Im Demonstrator erfolgt NC-Programmoptimierung durch deren Simulation zur Ermittlung der Spindel- und Achsströme. Ein KI-Modell bewertet diese anschließend und optimiert ggf. die Schnittparameter hinsichtlich Qualität und Produktivität. Mit einem weiteren KI-Modell erfolgt eine Near-time-Prozessüberwachung auf Basis der während der Bearbeitung ausgelesenen Maschinensignale (Spindel- und Achsströme) und NC-Daten. Hieraus werden sowohl die Prozessstabilität als auch eine Vorhersage der Produktqualität auf Basis einzelner Bearbeitungsmerkmale ermittelt und dem Maschinenbediener direkt grafisch angezeigt. Die Messergebnisse der gefertigten Bauteile werden zusammen mit den aufgezeichneten Maschinensignalen im entwickelten Wissensspeicher des AICoM-Systems abgelegt und stehen so sowohl für das weitere Training der KI-Modelle als auch zur manuellen Auswertung zur Verfügung. Mit dem Einsatz der Methoden des maschinellen Lernens konnte der Wissensraum eines der im Projekt entwickelten KI-Modelle sinnvoll erweitert werden, ohne dass weitere Daten aus realen Versuchen oder Bearbeitungen erforderlich waren. Der Einsatz des Demonstrators in der Fertigung eines Projektpartners zeigt, dass beim Fräsen eine signifikante Steigerung des Vorschubs bei gleichzeitiger Reduzierung der Bearbeitungszeit möglich ist.

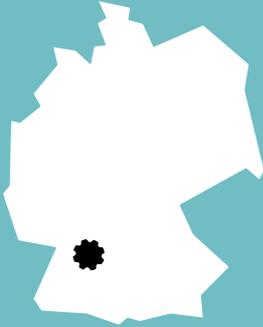


H HOFFMANN
www.hoffmann-gmbh.com

TRON MXD



3 AutoLern



FAKTEN

PROJEKT

Selbstlernende Werkzeugmaschinen für eine hocheffiziente Produktion

KOORDINATOR

TRUMPF Werkzeugmaschinen GmbH + Co. KG

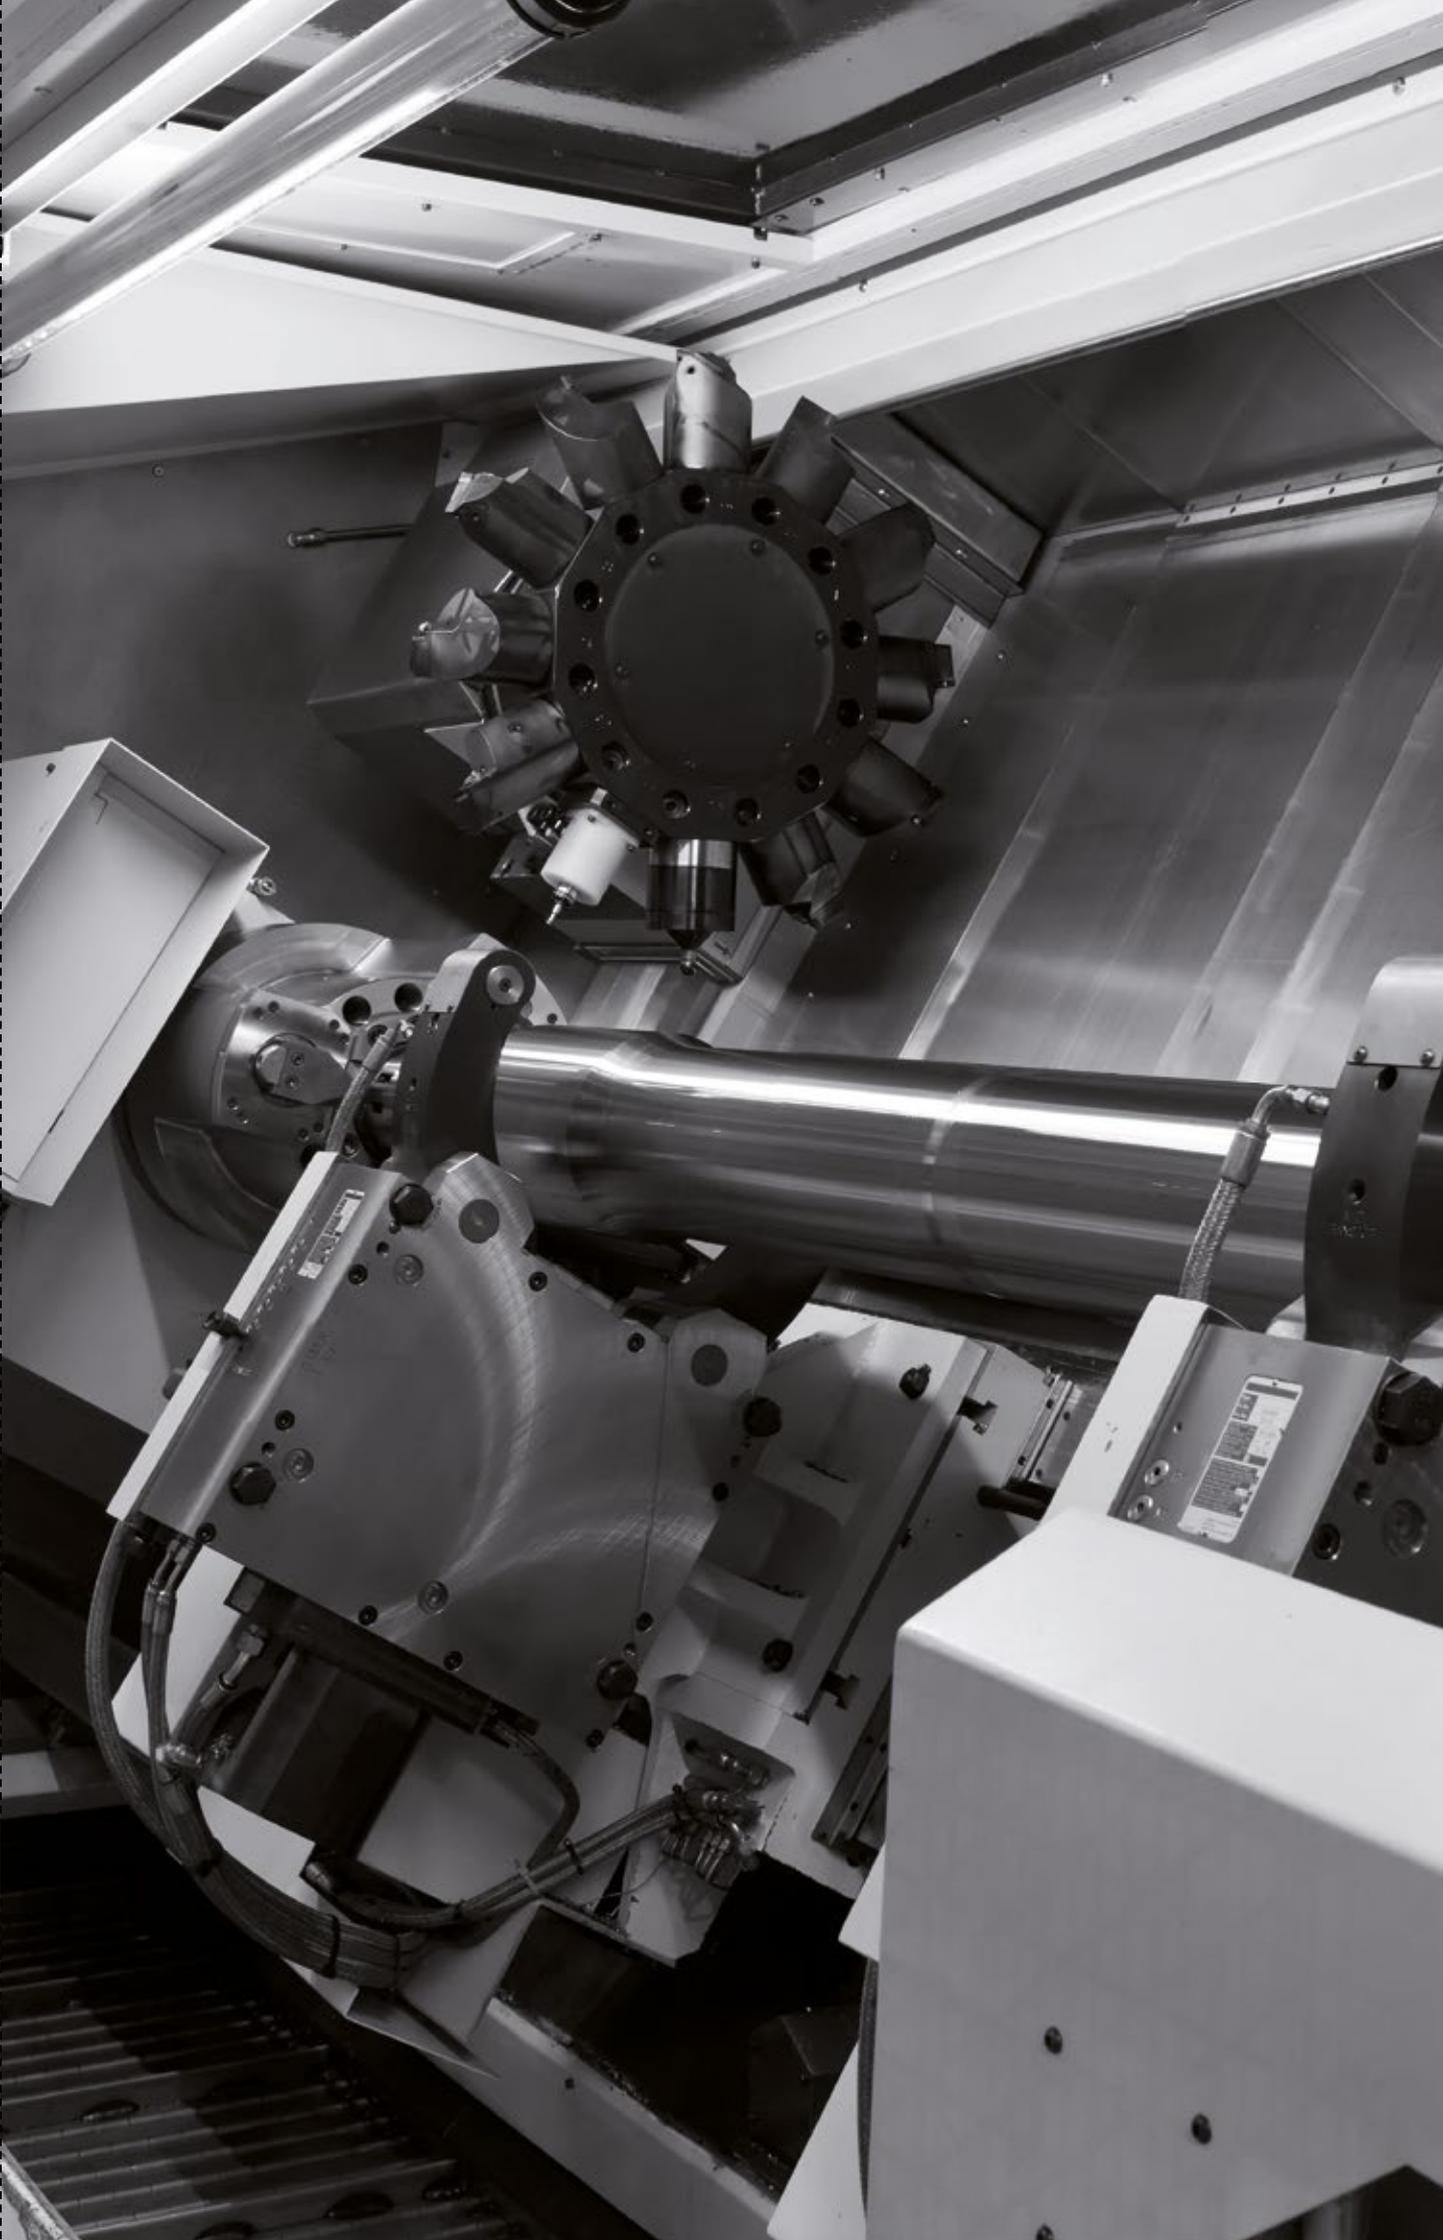
PARTNER

- Arburg GmbH + Co. KG**
Werker-Assistenz in der additiven Fertigung
- DIEFFENBACHER GmbH Maschinen- und Anlagenbau**
Anomalieerkennung und Live-Qualitätsauswertung in der Holzplattenproduktion
- Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung**
Entwicklung der Drift-Detection und Trainingspipelines
- Gebr. HELLER Maschinenfabrik GmbH**
Werker-Assistenz für die Fräsbearbeitung
- Karlsruher Institut für Technologie | wbk Institut für Produktionstechnik**
Erstellung von Industrialisierungskonzepten
- Point 8 GmbH**
Entwicklung der KI-Toolbox
- TRUMPF Werkzeugmaschinen GmbH + Co. KG**
Qualitätsregelkreise: Fehlschnitterkennung, Gratlänge, Ebenheitskompensation

Um wettbewerbsfähig zu bleiben, müssen Unternehmen schnell auf Veränderungen und Störungen im Produktionsprozess reagieren können. Künstliche Intelligenz (KI) bietet vielversprechende Lösungen für diese Herausforderungen. Durch den Einsatz von Sensoren, Vernetzung von Maschinen und maschinelles Lernen können komplexe Muster und Gesetzmäßigkeiten in Produktionsdaten erkannt werden. Dies ermöglicht die Optimierung von Produktionsprozessen und die Lösung komplexer Geschäftsprobleme.

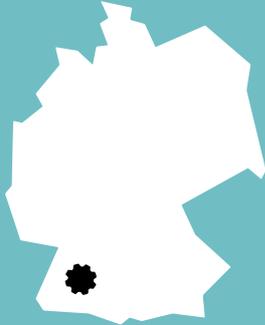
In Deutschland haben bereits 69 % der produzierenden Unternehmen mindestens einen Anwendungsfall mit KI umgesetzt. Auch im Maschinen- und Anlagenbau werden ML-Methoden in Pilotprojekten getestet, um die Produktivität, Produktqualität und Verfügbarkeit zu steigern. Die Industrialisierung dieser Ansätze bringt jedoch Herausforderungen mit sich, da die Betriebsphase der Maschinen im Kundenbetrieb von den Trainingsdaten abweicht. Die Änderungen der Randbedingungen, wie z. B. der Austausch einer Komponente, Verschleiß oder Schwankungen in den Materialeigenschaften, beeinflussen das Prozessoptimum. Das wird durch vortrainierte Modelle nicht automatisch berücksichtigt, was eine Entwicklung von Verfahren für die Überführung von KI-gestützten Produktionsprozessen in den Dauerbetrieb nötig macht. Das Ziel des Projektes AutoLern war es, Methoden zu entwickeln, die die Gültigkeit von KI-Modellen im Langzeitbetrieb von Maschinen unter realen industriellen Bedingungen kontinuierlich überprüfen und transparent mit dem Anlagenbediener kommunizieren. Dazu sollten Verfahren etabliert werden, die Modelle effizient an veränderte Randbedingungen anzupassen, wobei eine vollautomatische Anpassung nicht immer möglich ist. Zudem ist eine geeignete Systemarchitektur der Anlagensteuerung und sichere Schnittstellen zu Cloud-Lösungen der Maschinenhersteller erforderlich, um über den gesamten Produktionszyklus hinweg zu lernen und KI-Modelle zu aktualisieren.

Diese ambitionierte Zielstellung wurde methodisch durch die Forschungsinstitute betrachtet und in Kooperation mit den Industriepartnern in die vielseitigen Produktionskontexte eingebracht. Dabei wurde durch die Entwicklung von Deploy- und Pipelinemethodiken sowie durch die Sammlung der Methodiken in einer KI-Toolbox die Übertragbarkeit in alle Umgebungen sichergestellt. Die konkreten behandelten Problemstellungen reichten dabei von der Plananlagenkontrolle an Fräsmaschinen über Anomaliedetektion in additiven Fertigungsprozessen bis hin zu Qualitätsregelkreisen für die Holzplattenproduktion und die Blechbearbeitung.





4 DIPOOL



FAKTEN

PROJEKT

Digitaler Prozess-Onlineoptimierer für intelligente Lasermaschinen

KOORDINATOR

Automatic-Systeme Dreher GmbH

PARTNER

- Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e. V.**
Fraunhoferinstitut für Lasertechnik ILT
Entwicklung einer robusten Prozessführung lernender Lasermaschinen
- Karlsruher Institut für Technologie (KIT)**
Institut für Industrielle Informationstechnik IIIT
Entwicklung einer effizienten Signalanalyse mit maschinellem Lernen
- Precitec GmbH & Co. KG**
Integration smarter Systemtechnik u. Sensorik für das Laserschneiden
- 4D Ingenieurgesellschaft für Technische Dienstleistungen mbH**
Kombination multispektraler Schweißprozess-Sensorik mit KI-Methoden
- Marx Automation GmbH**
Implementierung maschinellen Lernens in die Lasermaschinensteuerung
- Automatic-Systeme Dreher GmbH**
Anforderungen, prototypischer Aufbau einer smarten Laser Blanking Line
- LASER Bearbeitungs- und Beratungszentrum NRW LBBZ GmbH**
Anforderungen u. Evaluierung einer lernenden 3D-Laserschweißtechnik

Laserschneiden für den Zuschnitt von Platinen für die Automobilproduktion, ausgehend von Coil-Material, das Laser-Blanking, ist gegenüber dem Einsatz von Stanzen eine sehr effiziente Methode, ressourcenschonend und flexibel zu produzieren, unter anderem aufgrund der Reduzierung des Verschnitts und der Flexibilität beim Nesting in einer kontinuierlichen Fertigung. Gerade bei kontinuierlich ablaufenden Prozessen ist eine große Zuverlässigkeit essenziell, weil die Folgen eines unerkannten Schnittabbrisses und der damit verbundene Anlagenstillstand aufwendiger zu beheben sind als das Ausschleusen einzelner Fehlteile bei Einzelplatinen. Der Trend zu kontinuierlicher Bearbeitung wie beim Laser Blanking forciert daher den Bedarf nach hoher Prozesssicherheit und zuverlässiger Prozessüberwachung. Automatisierte Fertigung und der Wunsch nach Predictive Maintenance, um ungeplante kostspielige Anlagenstillstände zu vermeiden, sind auch beim Laserschweißen treibende Faktoren für den Einsatz KI-unterstützter Überwachung.

Ziel im Forschungsprojekt DIPOOL war die stabile Überwachung, Qualitätssicherung und Optimierung von Lasermaschinen bei wechselnden Fertigungsaufgaben. Beim Laser-Blanking wurde dies aus systemtechnischer Sicht erreicht durch die Entwicklung eines Anlagenkonzepts, das mit dem Einsatz von zwei Schneidköpfen in einem gemeinsamen Arbeitsbereich ein Höchstmaß an Flexibilität und die Aufhebung von Einschränkungen in der Bahnplanung liefert, und durch die Steigerung der am bewegten Band prozesssicher einsetzbaren Schneidgeschwindigkeit.

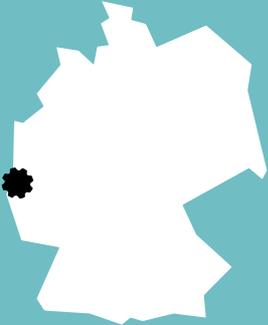
Kernpunkt für eine zuverlässige Überwachung war die Steigerung der Datenqualität. Dazu wird beim Schneiden dem Bearbeitungsprozess ein „minimalinvasives“ Lasermodulationsmuster aufgeprägt, worauf der Prozess kontinuierlich mit besonders charakteristischen, zustandsabhängigen Signalen antwortet. Als Sensoren dienen Fotodioden, die das Prozessleuchten erfassen. Diese Methode ermöglicht eine präzise Erkennung von Schnittabbrüchen. Beim Schweißen basiert die Verbesserung der Datenqualität auf dem Einsatz eines im Projekt entwickelten multispektralen Sensors und der wellenlängenabhängigen Signalanalyse.

Im Projekt wurden geeignete Lasermodulationsmuster und resultierende Antwortsignale identifiziert, für die ein CNN (Convolutional Neural Network) als bester Algorithmus aus dem Vergleich unterschiedlicher überwachter und nicht-überwachter Methoden der Künstlichen Intelligenz (KI) hervorging. Die Inferenz erfolgt auf einem echtzeitfähigen Prozessrechner mit FPGA, auf dem Datenerfassung, -vorverarbeitung und Inferenz mit 1 bis 2 Millisekunden getaktet sind und somit ausreichend schnell für den Hochgeschwindigkeitsschneidprozess ablaufen. Mit dem Einsatz von KI zur Interpretation der Prozesssignale beim Schneiden und Schweißen wird die Qualitätssicherung, Überwachung und Regelung der Prozesse robuster und kann auch den hohen Anforderungen der Echtzeitbewertung dynamischer Prozesse gerecht werden.





5 GeMeKI



PROJEKT

Generalisierung von menschenzentrierten KI-Applikationen für die Produktionsoptimierung

PARTNER

- aiXbrain GmbH (Koordinator)**
Menschenzentrierte KI-Lösungen für die Anwendungsbereiche Fügen, Trennen und Umformen
- CHIRON Group SE**
Anwendungspartner im Bereich Trennen zur Untersuchung von Fräsprozessen
- Franz Pauli GmbH & Co. KG**
Anwendungspartner im Bereich Umformen zur Untersuchung von Fließpressprozessen
- Fraunhofer-Institut für Produktionstechnologie IPT**
Wissenschaftliche und prozesstechnische Leitung des Bereichs Umformen
- meastream GmbH**
Datenererschließung und -vorverarbeitung für KI-Anwendungen im Bereich Umformen
- Miele & Cie. KG**
Anwendungspartner im Bereich Fügen zur Untersuchung von Klebprozessen
- MT Analytics GmbH**
Datenvorverarbeitung für KI-Anwendungen im Bereich Trennen
- Siemens AG**
Systemintegration, Steuerungstechnik und Untersuchungen im Bereich Trennen
- Innomotics GmbH – Business Unit Spindle Technology**
Sensorisierte Spindeln zur Datenererschließung im Bereich Trennen
- Werkzeugmaschinenlabor WZL der RWTH Aachen University**
Wissenschaftliche und prozesstechnische Leitung der Bereiche Fügen und Trennen
- XENON Automatisierungstechnik GmbH**
Automatisierungstechnik und Aufbau eines KI-Trainingsdatendemonstrators im Bereich Fügen
- YOUSE GmbH**
Entwicklungskonzepte zur Steigerung von Akzeptanz und Usability von KI-Assistenzsystemen

Bisher profitieren vor allem Großserienfertigungen von KI-Lösungen. Das Risiko hoher Investitionen und später Rentabilität werden bei dieser Größenordnung in Kauf genommen. KMU können solche wirtschaftlichen Risiken im Regelfall nicht eingehen, selbst wenn der mögliche Mehrwert durch KI sehr hoch ist. Und zur Eingrenzung von Risiken fehlen KMU Best-Practice-Beispiele, klare Nachweise für Verbesserungspotenziale sowie etablierte Standards. Mangelnde Akzeptanz und Unsicherheit in der Belegschaft beim Umgang mit großen Datenmengen und neuartiger Technologie wie Künstlicher Intelligenz stellen zusätzliche Hürden dar.

Ziel des Verbundprojekts GeMeKI ist daher die menschenzentrierte Zusammenführung von Produktionsausrüstung, Expertenwissen und Künstlicher Intelligenz in modulare und übertragbare Hardware- und Software-Bausteine, um die Leistungsfähigkeit, Flexibilität und Wirtschaftlichkeit komplexer Fertigungssysteme nachhaltig zu verbessern. Auf Basis der erzielten Projektergebnisse sollen Fertigungsunternehmen jeder Größe in die Lage versetzt werden, KI-Assistenzsysteme schnell und wirtschaftlich einzuführen und ihre Wettbewerbsfähigkeit zu steigern.

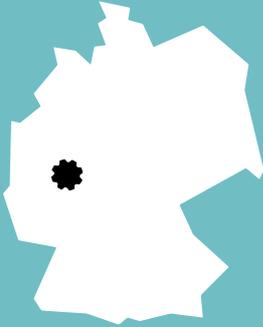
GeMeKI behandelt die drei Anwendungsfälle Fügen, Trennen und Umformen. In jedem Anwendungsfall wird Sensorik zur Datenererschließung in die Produktionsausrüstung integriert, erzeugte Rohdaten mit dedizierter Hardware und Software vorverarbeitet und anschließend mittels KI-Technologie in Zustandsanalysen und Handlungsvorschläge überführt. Deren Nutzung und Umsetzung durch Werkende steigert die Produktivität, Resilienz und Qualität der unterliegenden Fertigungssysteme. Best Practices zur Einführung der KI-Lösungen sowie individualisierbare User Labs und KI-Leitfäden nach Baukastenprinzip komplettieren diese Projektergebnisse, um die Akzeptanz von KI-Systemen zu erhöhen und die Skalierbarkeit von KI-Lösungen sicherzustellen.

Im Projekt wurden durchgängig partizipative Entwicklungsansätze angewendet, um Bedürfnisse von Werkenden und Experten an Lösungskomponenten in iterativen Updates berücksichtigen zu können und Akzeptanzbarrieren abzubauen. Aufbauend auf der jeweiligen Umsetzung einer generischen, modularen Sensorik-Middleware-KI-Systemarchitektur wurden in allen drei Anwendungsfällen Demonstratoren und Mensch-KI-Interaktionskomponenten zur gezielten Erzeugung von KI-Trainingsdaten, einschließlich erforderlicher Label, aufgebaut. Im Fokus stand hierbei vor allem das prozessparallele Labeling, um Werkende möglichst wenig vom Produktionsprozess abzulenken. Darauf aufbauend wurden KI-Applikationen zur Bewertung und Optimierung von Kleberauppenqualität (Fügen), Prozessauslegung (Trennen) und Werkzeugverschleiß (Umformen) entwickelt und als integrierte Gesamtlösung evaluiert. Abgerundet durch anwendungsgerechte Darstellungsformen der KI-Ergebnisse, gibt GeMeKI Werkenden ein mächtiges neues Digitalwerkzeug zur Optimierung ihrer Arbeit an die Hand, ohne ihre Rolle als letzte Entscheidungsinstanz zu kompromittieren.





6 IRLeQuM



FAKTEN

PROJEKT

Industrielles Reinforcement Learning zur Qualitätsregelung von Massivumformprozessen

KOORDINATOR

Mubea Tailor Rolled Blanks GmbH

PARTNER

- 
Mubea Tailor Rolled Blanks GmbH, Attendorf
 Prozessexpertise und Pilotanwendung im flexiblen Walzen
 - 
Eichsfelder Schraubenwerk GmbH, Heiligenstadt
 Prozessexpertise und Pilotanwendung im Vollvorwärtsfließpressen
 - 
Schomäcker Federnwerk GmbH, Melle
 Prozessexpertise und Pilotanwendung in der Warmumformung
 - 
IconPro GmbH, Aachen
 Weiterentwicklung und Implementierung von Algorithmen
 - 
Quality Automation GmbH, Stolberg
 Integration sowie Zusammenführung von Daten inkl. der entsprechenden Schnittstellen
 - 
Werkzeugmaschinenlabor WZL der RWTH Aachen, Aachen
 Forschung im Bereich Reinforcement & Transfer Learning, Prozesssimulation und QRK-Konzeptionierung
- Assoziierte Partner:
- 
MAWI GmbH, Bad Wildbad & Schuler Pressen GmbH, Göppingen
 Erfahrungsaustausch

Instabilitäten in Massivumformprozessen führen aufgrund von externen Einflussgrößen und unbekanntem Zusammenhang zwischen Prozessparametern und Qualitätsmerkmalen von Produkten trotz vorhandener Prozessregelungen zu Ausschuss. Aktuelle Konzepte zur Regelung basieren auf implizitem Bedienerwissen und der automatisierten Regelung einzelner Prozessparameter. Um die Regelung jedoch noch weiter zu objektivieren und Abweichungen noch weiter zu reduzieren, werden neue, holistische Ansätze untersucht. Ein Mittel zur übergreifenden Kompensation von Qualitätsabweichung sind Qualitätsregelkreise, QRK. In Kombination mit Ansätzen des maschinellen Lernens, hier dem Reinforcement Learning, RL, und dem Transfer Learning, TL, bieten QRK das Potenzial den Ausschuss zu reduzieren. Dies geschieht über eine automatische Adaption der Anlagenparameter bei auftretenden Instabilitäten.

Das Ziel des Forschungsprojektes IRLeQuM ist die Entwicklung eines Verfahrens zur Implementierung von neuartigen Reglern, basierend auf RL und TL, in QRK von Massivumformprozessen.

Damit eine RL-basierte Regelung überhaupt ermöglicht werden kann, wird zunächst die notwendige IT-Infrastruktur definiert und umgesetzt. Die RL-Regelung bietet den Vorteil, dass zum einen alle qualitätsrelevanten Informationen, wie zum Beispiel Prozessparameter, Umgebungsbedingungen oder Rohstoffeigenschaften, in die Regelung mit einbezogen werden können. Zum anderen kann das implizite Bedienerwissen der Regelung dauerhaft nutzbar gemacht werden.

Um die Anlernzeit des RL-Algorithmus zu reduzieren und Ressourcen zu schonen, wird der Algorithmus nicht direkt am Realprozess trainiert, sondern an einer stochastischen Prozesssimulation. Die an der Simulation gewonnenen Erkenntnisse werden anschließend mittels TL auf den QRK des Regelkreises übertragen.

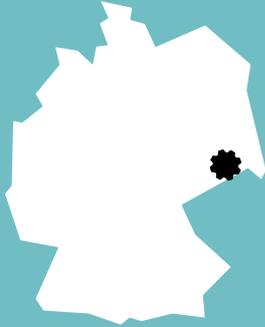
Das Ergebnis des Forschungsprojekts wird eine Qualitätsregelung von Massivumformprozessen sein, die automatisiert, umfassend und in Echtzeit Prozesse regelt und die Qualität der Prozesse optimiert. Die gesteigerte Prozessqualität erhöht die Qualität der Produkte und reduziert den Ausschuss.

Das Forschungsprojekt IRLeQuM, mit einer Projektdauer von drei Jahren, ist zum 1. Juni 2021 gestartet und wird in Zusammenarbeit des Lehrstuhls für Fertigungsmesstechnik und Qualitätsmanagement, des Lehrstuhls für Technologien der Fertigungsverfahren sowie der Unternehmen Mubea Tailor Rolled Blanks GmbH als Konsortialführer, Eichsfelder Schraubenwerke GmbH, IconPro GmbH, Schomäcker Federnwerk GmbH, Quality Automation GmbH und der assoziierten Partner MAWI GmbH und Schuler Pressen GmbH durchgeführt.





7 KausaLAssist



FAKTEN

PROJEKT

Kausale Graphen als lernendes Assistenzsystem für automatisiertes Fehlermanagement in der Produktion

KOORDINATOR

Fraunhofer-Institut für Werkzeugmaschinen und Umformtechnik IWU, Abteilung Digitalisierung in der Produktion

PARTNER

- Fraunhofer-Institut für Werkzeugmaschinen und Umformtechnik IWU**
Entwicklung des KI-Systems zum Erlernen und Anwenden kausaler Graphen
- Schuster Maschinenbau GmbH**
Aufbau KI-befähigter Werkzeugmaschinen mit integriertem Fehlermanagement
- KAMAX Tools & Equipment GmbH & Co. KG**
Automatisiertes Fehlermanagement in komplexer Kleinserienfertigung
- Industrie-Partner GmbH Coswig**
Aufbau einer Fehlermanagementlösung für eine autonome Roboterzelle
- ISG Industrielle Steuerungstechnik GmbH**
Virtuelle Trainings- und Testumgebung für KI-Algorithmen in der Betriebsphase
- SEITEC GmbH**
KI-Befähigung von Produktionsmaschinen und Entwicklung der OPC-UA-Infrastruktur
- queo GmbH**
Software für ganzheitliches, KI-unterstütztes Fehlermanagement in der Produktion
- Institut für Angewandte Informatik e. V.**
KI-gestützte Lösungsstrategieentwicklung

Ausgangslage/Motivation

Unternehmen der Fertigungsindustrie stehen vor der Herausforderung, die Verfügbarkeit komplexer Produktionssysteme zu maximieren und Stillstandzeiten zu minimieren. Bei Störungen sieht sich das Bedienpersonal oft mit einer Flut von Zustandsmeldungen konfrontiert. Die Fähigkeit, daraus die richtigen Schlüsse zu ziehen und Störungsursachen effizient zu identifizieren, hängt stark von Qualifikation und Erfahrung ab.

Diese Situation kann zu langen Ausfallzeiten und hohem Personalaufwand führen, was Produktivität und Wettbewerbsfähigkeit beeinträchtigt. Die zunehmende Komplexität verstärkt diese Problematik. Vorhandene Diagnose- und Assistenzsysteme sind selten, oft unflexibel und erfordern hohe Rechenleistung oder viele Benutzereingaben. Dies unterstreicht die Notwendigkeit für innovative Lösungen im intelligenten Fehlermanagement.

Zielsetzung

Das BMBF-Projekt KausaLAssist zielt darauf ab, ein intelligentes Fehlermanagementsystem mittels erklärbarer KI zu entwickeln. Kernstück ist ein gerichteter Graph, der Fachwissen mit KI-gestützten Erkenntnissen über Kausalbeziehungen in Produktionssystemen vereint. Dieser Ansatz soll die Produktivität steigern, Ausfallzeiten reduzieren und die Wettbewerbsfähigkeit verbessern.

Zentral ist die Entwicklung einer benutzerfreundlichen Assistenzlösung zur Unterstützung bei Fehleridentifikation und -behebung. Der kausale Graph soll Ursache-Wirkung-Beziehungen transparent darstellen und als Entscheidungsgrundlage dienen. Das System soll kontinuierlich lernen, um langfristige Zuverlässigkeit sicherzustellen. Zudem strebt das Projekt Transparenz von KI-Entscheidungen, automatisierte Fehlerbehebungsstrategien und Erprobung in verschiedenen Anwendungsfällen an.

Erreichte Ergebnisse

In der noch laufenden Entwicklung wurden bereits wichtige Fortschritte erzielt. Ein Meilenstein war die Entwicklung einer OPC-UA-Dateninfrastruktur zur Sammlung von Maschinenmeldungen der ganzen Linie, ergänzt durch einen Client für Datenverfügbarkeit und -speicherung. Ein digitaler Zwilling ermöglicht die virtuelle Inbetriebnahme und Validierung der KI-Systeme unter realitätsnahen Bedingungen.

Hervorzuheben ist die Integration des KausaLAssist-Ansatzes in Steuerungssysteme. Eine intuitive Benutzeroberfläche stellt Meldungen, Störungen, mögliche Ursachen und Lösungsvorschläge übersichtlich dar. Die implementierte Datenbank dient der Fehleranalyse und Informationsübermittlung an Maschinenhersteller.

Zukunftsweisend sind Fortschritte bei der Entwicklung autonomer Fehlerbehebung durch Roboterzellen, die Anweisungen vom System umsetzen können. Erste Anwendungen zeigen bereits eine deutliche Reduktion der Stillstandzeiten und eine verbesserte Fehlerbehebung, was die Produktivität steigert.

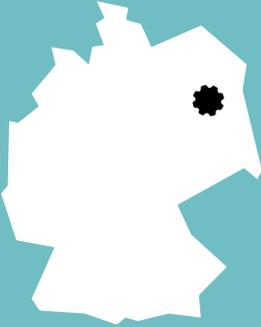
Das Projekt wird kontinuierlich weiterentwickelt, mit dem Ziel, bis Projektende Ende 2024 eine deutliche Stillstandsreduktion nachzuweisen.





8

KIKA-IPK



FAKTEN

PROJEKT

KI-kognitionsunterstützendes Assistenzsystem zur Inprozesskontrolle in der Fertigung

KOORDINATOR

PSI Metals GmbH

PARTNER

- 📍 **PSI Metals GmbH (ab September 2024: PSI Software SE), Berlin**
KI-Cloud-Dienste, Schnittstellen und Plattform
- 📍 **Technische Universität Berlin, FG Industrielle Automatisierungstechnik, Institut für Werkzeugmaschinen und Fabrikbetrieb IWF**
Assistenzsystem zur Kompensation von Qualitätsabweichungen
- 📍 **GEFERTEC GmbH, Berlin**
Produktcharakterisierung beim 3D-Metalldruck
- 📍 **RELIMETRICS GmbH, Berlin**
ML-Verfahren zur produktmerkmalgestützten Prozessregelung
- 📍 **BioFluidix GmbH (seit November 2022: Hamilton Freiburg GmbH), Freiburg**
Inprozessregelung zur Echtzeitkompensation von Qualitätsabweichungen
- 📍 **DiHeSys GmbH, Schwäbisch Gmünd**
Personalisierter Medikamentendruck
- 📍 **Gestalt Robotics GmbH (ausgeschieden im November 2023)**
ML-Verfahren zur Produktcharakterisierung

Skalierbare KI-Assistenz zur autonomen Inprozesskontrolle und -regelung

Der industriellen Anwendung von KI-Methoden stehen in der Praxis die Kosten der Datenaufnahme, fehlende Trainingsdaten und ein Mangel an KI-Fachkräften mit Prozesskompetenz entgegen.

Ziel von KIKA-IPK ist die Entwicklung von skalierbaren KI-Cloud-Diensten, die durch einfaches „Plug-and-Play“ aus dem Prozesswissen der Akteure lernt, um bildgestützte Produktcharakterisierung, Kompensation von Qualitätsabweichungen und autonome Prozessanpassung auf neue Produktmerkmale zu ermöglichen.

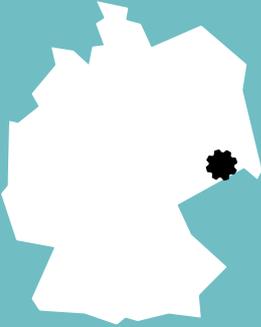
Im Rahmen des FuE-Vorhabens werden Verfahren entwickelt, die es ermöglichen, aus visuellen Produktmerkmalen auf Prozesskenngrößen zurückzuschließen, die kaum messbar sind. Hierdurch wird es möglich, den Prozess gezielt so zu regeln, dass Qualitätsabweichungen während der Fertigung kompensiert und auf neue Produktmerkmale effizient angepasst werden. Dazu werden die Bild-, Prozess- und Materialdatenströme sowie das Nutzerfeedback während der Fertigung über die Schnittstelle des „KI-kognitionsunterstützenden Assistenzsystems“ (KIKA) analysiert und die Ergebnisse nachvollziehbar den Akteuren sowie der Maschinensteuerung in Echtzeit übermittelt. Die KI-Dienste werden in zwei Szenarien für die additive Fertigung (3D-Metalldruck) und für den personalisierten Medikamentendruck integriert und das Ressourceneffizienzpotenzial in der industriellen Anwendung demonstriert.

Nach einem Erfolg des FuE-Vorhabens werden die KI-Dienste bis zur Produktreife weiterentwickelt und über die PSI-Cloud verschiedenen Kunden angeboten. Für die PSI Software AG und die zahlreichen KI-Startups wird damit ein neuer Markt und eine größere Reichweite als Drittanbieter für KI-Dienste ermöglicht. Durch die hohe Skalierbarkeit des gewählten Ansatzes können vor allem in der Kleinserienfertigung und individualisierten Massenfertigung neue Märkte mit der KIKA-IPK-Technologie erschlossen und so die Wettbewerbsfähigkeit bei den Produzenten nachhaltig gesteigert werden.





9 MEDIUS



FAKTEN

PROJEKT

Multi-Ebenen-gekoppelte Laserproduktionstechnologie mit KI-basierter Entscheidungsplattform

KOORDINATOR

SQL Projekt AG

PARTNER

- 📍 **IS Predict GmbH**
Konzeption und Umsetzen einer selbstlernenden Lösung, basierend auf Künstlicher Intelligenz
- 📍 **RADIUSMEDIA KG**
Anforderungsanalyse und Aufbau eines Augmented-Reality-Systems in Kontext mit der Laseroberflächenbearbeitung
- 📍 **Gesellschaft für Bild- und Signalverarbeitung (GBS) mbH**
Aufbau und Umsetzen eines Moduls zur In-line-Topografieanalyse
- 📍 **Pulsar Photonics GmbH**
Systemintegration, Validieren und Verwerten eines AR- und KI-gestützten Laseranlage
- 📍 **Deutsches Forschungszentrum für Künstliche Intelligenz GmbH**
Kognitive Belastungsanalyse kognitiver und affektiver physiologischer Daten für AR-Systeme
- 📍 **Fraunhofer-Institut für Werkstoff- und Strahltechnik**
Laserprozessentwicklung sowie inhaltliche Konzeption und Umsetzen einer Vorhersageplattform für Laseroberflächenbearbeitung
- 📍 **Erich Utsch AG**
Anforderungsanalyse; Evaluieren funktionaler Oberflächen

Laserbasiertes Oberflächenfunktionalisieren: Aus dem Labor in die Industrie

Der Einsatz von Laserstrahlung als Werkzeug in der Produktion ist industriell etabliert und hat zu einem Wandel geführt, bei dem klassische Fertigungsverfahren durch laserbasierte Prozesse ersetzt werden. Beispielsweise kann die beim Implantatherstellung etablierte Methode des Sandstrahlens durch laserbasierte Ansätze ersetzt werden, sodass Prozesse vereinfacht und gleichzeitig umweltschonender werden. Lasertechnologien sind zusätzlich gut digitalisierbar, so dass autonome Automatisierungsszenarien und selbstregelnde Prozesse ermöglicht werden können. Laserprozesse sind aber auch meist komplex und erfordern spezifisches ingenieurwissenschaftliches Domänenwissen sowie eine langjährige Erfahrung des Maschinenbedieners, um optimale Prozessergebnisse zu erreichen.

Ziel von MEDIUS war es, die traditionelle Produktionsumgebung zum Herstellen laserbasierter funktionaler Oberflächen durch gekoppelte, KI-gestützte Vorhersagesysteme so zu erweitern, dass die Komplexität und Barriere zur Technologienutzung reduziert wird. In Folge lassen sich komplexe und zeitintensive Konfigurations- und Entscheidungsprozesse wie die Maschinensteuerung und -wartung, Auswahl optimaler Prozessparameter, Qualitätsbewertung und -dokumentation durch den Einsatz KI-basierter Vorhersagesysteme in Kombination mit intuitiven Mensch-Maschine-Interaktionen vereinfachen.

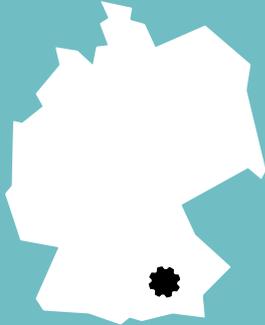
In MEDIUS wurden dafür Daten aus verschiedenen Maschinenquellen zusammengefasst und in Form eines Datenlagers („ganzheitliche Informationsquelle“) bereitgestellt. Die gesammelten Informationen sind Maschinendaten, optimale Prozessparameter sowie Informationen zur hergestellten Oberflächentopografie, die anschließend mit KI-basierten Ansätzen verarbeitet werden. Die daraus abgeleiteten Handlungsempfehlungen werden den Nutzenden über eine visuelle Schnittstelle durch Augmented Reality mit Gestiksteuerung bereitgestellt. Die Qualität der Mensch-Maschine-Interaktion wird zusätzlich unter Berücksichtigung des kognitiven und affektiven/emotionalen Zustands der BedienerInnen evaluiert. Die Vorteile lernender Produktionstechnologien werden im Rahmen des Projektes an einer Laseranlage des Typs RDX500 des Projektpartners Pulsar Photonics demonstriert.

Das Potenzial des Projektes besteht auch in dem Evaluieren der AR-gestützten lernenden Lasermaschine zum Erschließen laserfunktionalisierter Oberflächen, vor allem in den Branchen Medizintechnik, Werkzeugbau, Haushaltsgeräte sowie Luft- und Raumfahrt, als effektive und effiziente Arbeitsumgebung für die Nutzenden der Zukunft. In Folge wird das Bearbeiten kleiner Losgrößen produktiver, da aufwendiges Einrichten der Laserprozesse durch AR- und KI-Systeme vereinfacht wird.





10 MetaLearn



FAKTEN

PROJEKT

KI zur Entscheidungsunterstützung bei der Parametrierung von Produktionsprozessen von komplexen kundenindividuellen Spezialprodukten mit kleinen Serien

KOORDINATOR

J.M. Voith SE & Co KG: Sabrina Ruf, M.Sc.
& Hochschule Reutlingen, ESB Business School: Prof. Dr. Günter Bitsch

PARTNER

- J.M. Voith SE & Co KG**
Bereitstellung industrieller Anwendungsfälle und Produktionsdaten für KI-Modelle
- Hochschule Reutlingen ESB Business School**
Entwicklung und Adaption von KI-Methoden für datenarme Produktionsprozesse
- FZI Forschungszentrum Informatik**
Entwicklung von erklärbaren und interaktiven KI-Systemen
- Paul Horn GmbH**
Optimierung von Schleifprozessen und Bereitstellung von Produktionsdaten aus solchen Prozessen

Die Produktion von kundenspezifischen und qualitativ hochwertigen Produkten steht vor zahlreichen Herausforderungen. Besonders komplex wird es, wenn kleine Stückzahlen produziert werden, bei denen eine Vielzahl von Faktoren die Qualität beeinflusst – darunter Bauteilgeometrien, Materialeigenschaften und Maschineneinstellungen. Diese Faktoren wirken oft in Kombination, was es schwierig macht, optimale Parameter für eine fehlerfreie Produktion zu bestimmen. Zudem sind die verfügbaren Produktionsdaten aufgrund der niedrigen Stückzahl begrenzt und teilweise lückenhaft.

Zielsetzung: KI-Methoden auf die komplexe und datenarme Produktionsumgebung anzuwenden, um die Produktqualität zu verbessern und Rüstzeiten zu verkürzen. Durch den Einsatz von KI sollte ein besseres Verständnis der Zusammenhänge zwischen den verschiedenen Produktionsparametern erreicht werden, um die Effizienz und Robustheit der Prozesse zu steigern. Zwei spezifische Anwendungsfälle wurden fokussiert: die Herstellung von Spezialwerkzeugen und der Getriebebau. In beiden wurde der Einsatz von KI zur Optimierung der Produktionsparameter und zur Reduktion von Qualitätsmängeln getestet.

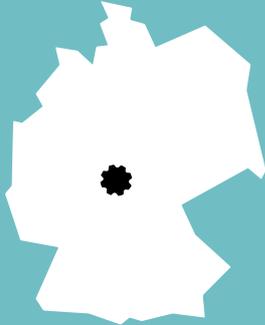
Erreichte Ergebnisse: Es wurden KI-Algorithmen entwickelt, die in der Lage sind, auch mit kleinen Datenmengen robuste Vorhersagen für die Produktionsprozesse zu treffen. Das Projekt zeigte, dass durch den Einsatz von KI in komplexen und datenarmen Produktionsumgebungen erhebliche Verbesserungen in Effizienz und Qualität erzielt werden können. Die Ergebnisse eröffnen vielversprechende Perspektiven für die zukünftige Anwendung von KI auch im produzierenden Mittelstand mit seinem spezialisierten, variantenreichen Produktportfolio.





11

pAInt-Behaviour



FAKTEN

PROJEKT

Effizienzsteigerung von Lackierprozessen durch mehrschichtige Vernetzung von Prozess- und Qualitätsdaten mittels selbstlernender Verhaltensmodelle

KOORDINATOR

Jochen Rieser

PARTNER

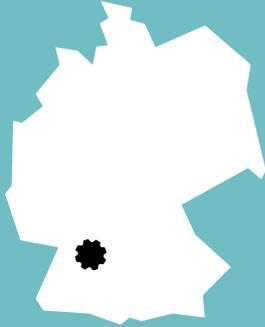
- b+m surface systems GmbH**
Datenerhebung, Verdichtung und Bereitstellung von Beispieldaten und Produktionsdaten
- AOM Systems GmbH**
Überwachung, Auswertung des Zerstäubungsvorgangs und Spraycharakterisierung
- Helmut Fischer GmbH Institut für elektronische Messtechnik**
Ermittlung von Qualitätsdaten mittels berührungsloser Schichtdickenmessung
- Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA**
Verhaltensmodell zur Ableitung der Produktqualität aus dem Lackierprozess

Das Projekt „Effizienzsteigerung von Lackierprozessen durch mehrschichtige Vernetzung von Prozess- und Qualitätsdaten mittels selbstlernender Verhaltensmodelle“ mit dem Akronym pAInt-Behaviour fokussiert sich auf den Bereich der Kunststofflackierung im Automobil- und Nutzfahrzeugsektor. In diesem Bereich haben wir es mit einem hohen Produktvolumen und daher mit einem hohen Bedarf an Qualitätsprognose zu tun. Zum anderen besteht in Lackierprozessanlagen ein sehr hoher Automatisierungs-/Digitalisierungsgrad, der den Einsatz von KI-Systemen erfolgversprechend macht. Hauptursachen für Ausschuss und Nacharbeit sind, neben Staubeinschlüssen, vor allem durch Schichtdickenabweichungen verursachte Fehler (Läufer, Farbtonabweichung), weshalb sich das Projekt auf die Einhaltung der Lackschichtdicke konzentriert. Trotz des sehr hohen Automatisierungsgrades von Lackieranlagen und sensorischer Überwachung gilt die Prozesskette der Beschichtung nicht als beherrschbar im Sinne der Prozessfähigkeitsanalyse. Dies liegt einerseits an mangelnden physikalischen Beschreibungsmodellen und andererseits an multikausalen Zusammenhängen zwischen der Lackchemie und den Prozesseigenschaften. Um die Ausschussraten zu verringern, die Anlagenproduktivität durch geringere Störzeiten zu erhöhen und zeitgleich die Prozesse zu stabilisieren, ist eine Technologie gefragt, welche die Prozessdaten feingranular und systembruchfrei erfasst und mit den Qualitätsdaten verbindet. An diesem Punkt setzt das Projekt pAInt-Behaviour an. In dem Vorhaben werden die Qualitätsdaten mit den Prozessdaten durch ein feingranulares Verhaltensmodell miteinander verknüpft, um Qualitätsabweichungen zu erklären und frühzeitig zu erkennen. Die angestrebten Ziele in diesem Projekt sind eine Reduzierung der Fehlerquote, eine Verringerung des jährlichen Lackverbrauches, eine Verkürzung der Anlaufzeit neuer Farben und mehr Transparenz im Beschichtungsprozess. Im Projekt wird Komplexität bei der Spritzlackierung durch eine mehrstufige Überwachung der Prozesse aufgelöst. Es werden Prozessdaten aus der Anlagensteuerung, optische Überwachung des Spritzstrahls mittels SpraySpy®, Messung der Schichtdicke mittels Terahertzstrahlung und Kontrolle der finalen Qualität miteinander kombiniert. In einem Demonstrator am Fraunhofer IPA wurde die Prozesskette dargestellt und es konnte gezeigt werden, dass sowohl Parameterabweichungen, Defekte in Equipment und auch Abweichungen im Material schon im Spritzstrahl detektiert werden konnten. Es wurden dafür Abweichungen in Lackausbringmenge, in der Drehzahl des Hochrotationszerstäubers, der Luftmenge eingebracht, defekte Glockenteller und Lenklufthauben eingesetzt und sowohl die Viskosität als auch die Pigmentierung variiert. Diese Änderungen sind dann sowohl im Spray als auch im Endprodukt (dargestellt durch den Farbton) sichtbar.





12 ProKInect



FAKTEN

PROJEKT

Herstellerübergreifende und verteilte KI in Werkzeugmaschinen

KOORDINATOR

TRUMPF Werkzeugmaschinen SE & Co. KG, Ditzingen

PARTNER

- TRUMPF Werkzeugmaschinen SE & Co. KG, Ditzingen**
Entwicklung intelligenter Maschinenüberwachung, Bereitstellung von Zustandsdaten der Maschine
- WITTENSTEIN SE, Igersheim**
Entwicklung intelligenter Komponentenüberwachung, Bereitstellung von Zustandsinformationen der Komponente
- TVARIT GmbH, Frankfurt**
Bereitstellung digitaler Infrastruktur für Echtzeitsignalverarbeitung und KI-Anwendungen in geschützten Datenräumen
- Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF, Darmstadt**
Entwicklung von KI-basierten Lösungen, die Expertenwissen erklärbar und transparent integrieren

Innovative Lösungen für die vorausschauende Wartung von Werkzeugmaschinen

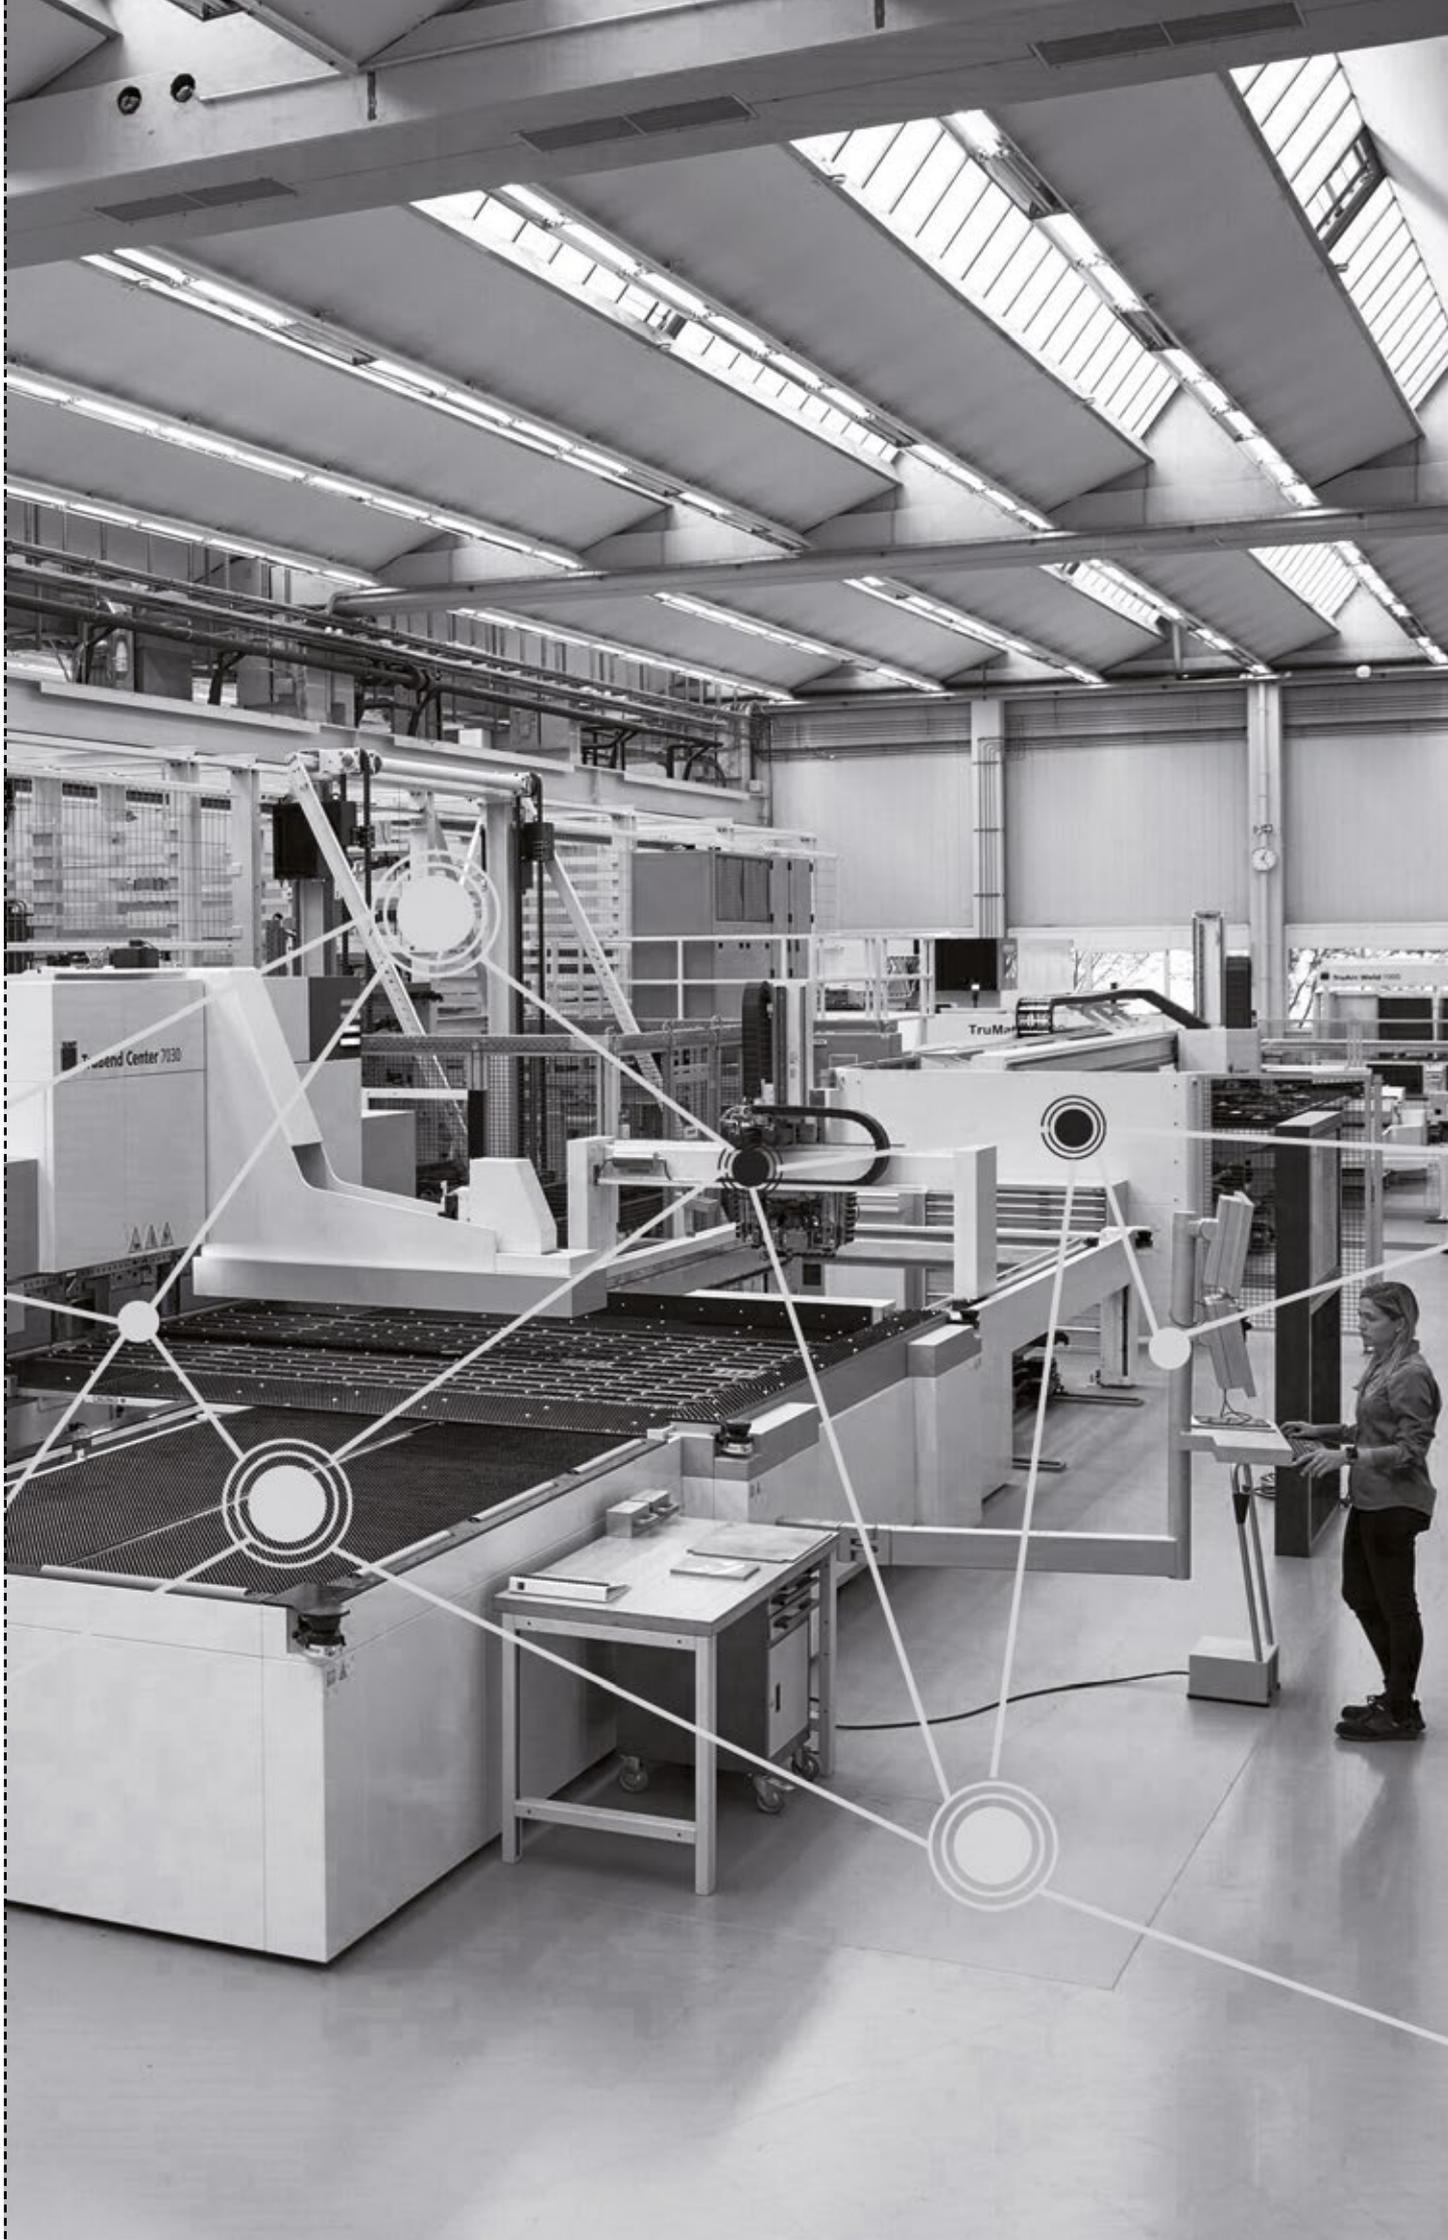
In der modernen Industrie steht die Zustandsüberwachung von Maschinen vor einer großen Herausforderung: Es fehlt an Zusammenarbeit zwischen Komponentenlieferanten, Maschinenherstellern und Maschinenbetreibern. Oft stehen betriebsgenerierte Daten nur einer Partei zur Verfügung, was kombinierte Analysen erschwert. Dieser Mangel an Kooperation behindert den Einsatz von KI-basierten Überwachungssystemen, die neben großen Datenmengen besonders das Kontextwissen benötigen, um präzise Fehlerdiagnosen zu ermöglichen.

Vor diesem Hintergrund entwickelt ProKInect ein System, das die ganzheitliche Diagnose von Maschinen inklusive ihrer Komponenten ermöglicht. Ziel des Projekts ist es, alle verfügbaren Informationen - von Sensoren über Komponenten, bis hin zu Maschinendaten - zu integrieren, während gleichzeitig die Datensouveränität der beteiligten Unternehmen gewährleistet wird. Durch diese umfassende Integration soll die Zuverlässigkeit und Verfügbarkeit von Maschinen optimiert, die Lebensdauer verlängert sowie Wartungskosten und ungeplante Ausfallzeiten reduziert werden.

ProKInect hat zunächst eine technische Infrastruktur geschaffen, die das zeitsynchrone, hochfrequente Erfassen der verteilten Datenquellen sowie ein sicheres Datenmanagement ermöglicht. Für eine TRUMPF-Laserschneidmaschine mit intelligenten WITTENSTEIN-Planetengetrieben wurden relevante Fehlerbilder identifiziert und erste Lösungen zur herstellerübergreifenden Zustandsdiagnose entwickelt. Ein Schwerpunkt dabei war die systematische Integration von Expertenwissen, um die Transparenz und damit die Akzeptanz solcher KI-Systeme zu steigern. Zudem ermöglicht die A-priori-Integration von empirischem und erfahrungsabhängigem Wissen die Entwicklung von präzisen und zuverlässigen Überwachungssystemen auch bei geringem Trainingsdatenbestand.

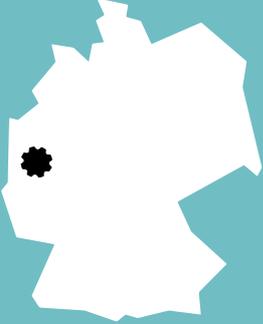
In Zusammenarbeit der Projektpartner entstand eine funktionale Architektur für die Zustandsüberwachung mit verteilten KI-Agenten sowie eine Infrastruktur, die eine einfache Implementierung dieser Agenten ermöglicht. Dabei kann jeder Algorithmus auf die ihm verfügbaren Daten und Kennwerte zugreifen. Die entstehenden Diagnoseergebnisse der verschiedenen Partner werden dann unter Berücksichtigung von Unsicherheiten kausal zusammengeführt. Über verschiedene Visualisierungen können die Zustandsinformationen, detaillierte Kenngrößen und Rohdatenverläufe eingesehen werden.

Die prototypische Umsetzung dieses Systems wurde in einer abschließenden Live-Demo validiert, bei der unter anderem die Erkennung von fehlerhafter Maschinenneigung und Umkehrspiel am Zahnstange-Ritzel-Antriebssystem präsentiert wurde. Das Projekt demonstrierte damit, wie durch die automatisierte Fehlerdiagnose auf Basis geteilter Daten die Serviceeinsatzzeit erheblich verkürzt und eine frühzeitige Reaktion auf Veränderungen im Maschinenzustand ermöglicht wird.





13 ProSLAM



FAKTEN

PROJEKT

Produktion durch selbstlernende additive Fertigungsmethoden

KOORDINATOR

BCT-Steuerung und DV-Systeme GmbH

PARTNER

- BCT-Steuerung und DV-Systeme GmbH, Dortmund**
Entwicklung einer Software zur adaptiven Prozessführung
- Fraunhofer Institut für Lasertechnik, Aachen**
LMD-Prozessentwicklung und Sensorintegration
- Precitec GmbH & Co. KG**
Laserschweißkopf & OCT-Entwicklung
- Diondo GmbH, Hattingen**
CT-Analysen
- Point8 GmbH, Dortmund**
Entwicklung einer Offline-KI
- Resolto Informatik GmbH, Herford**
Entwicklung einer Online-KI

Additive Fertigungsverfahren wie das Laser Material Deposition (LMD) gewinnen in der Industrie zunehmend an Bedeutung, erfordern jedoch eine präzise Prozesssteuerung, da kleinste Abweichungen Qualitätsmängel verursachen können. Die Komplexität des LMD-Prozesses liegt in der Überwachung zahlreicher Parameter wie Temperatur, Schmelzbad- und Bauteilgeometrie. Eine Herausforderung besteht darin, diese Parameter während des Prozesses zu erfassen, auszuwerten und in Echtzeit Anpassungen vorzunehmen. Die Integration vielfältiger Datenquellen in ein benutzerfreundliches Steuerungssystem erschwert den praktischen Einsatz solcher Technologien zusätzlich.

Das Forschungsprojekt ProSLAM hat das Ziel, eine autonome, KI-basierte Prozessplanung und -steuerung für das LMD-Verfahren zu entwickeln. Dies beinhaltet die automatisierte Erfassung und Analyse relevanter Prozessdaten sowie die Nutzung von KI-Methoden zur Optimierung der Materialnutzung und Prozessqualität. Im Fokus stehen zwei zentrale KI-Systeme: eine Offline-KI, die Prozessdaten mit Bauteileigenschaften korreliert, und eine Online-KI, die diese Daten in Echtzeit für Prozessanpassungen nutzt. Unterstützt wird dies durch eine maschinennahe Softwarelösung, die Sensordaten erfasst, in einer gemeinsamen Benutzeroberfläche zusammenführt und die Prozessüberwachung sowie Fehlervermeidung automatisiert.

Im Rahmen von ProSLAM wurden bedeutende Fortschritte bei der Entwicklung eines umfassenden Datenerfassungssystems erzielt. Ein KUKA-Industrieroboter wurde mit einer speziell entwickelten Laserschweißoptik ausgestattet, die Sensoren wie einen OCT-Sensor, eine CMOS-Kamera, ein Pyrometer und einen Laserlinienscanner umfasst. Diese ermöglichen eine hochpräzise, berührungslose Erfassung der Prozessparameter. Ergänzt wird dies durch die Implementierung eines digitalen Zwillings, der örtlich aufgelöste Prozessdaten beinhaltet.

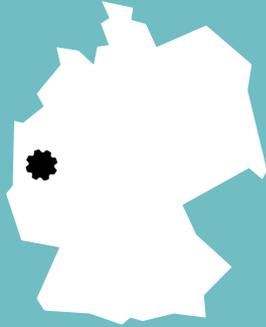
Für die Entwicklung der Offline-KI zur Korrelation von Prozessdaten mit Bauteildefekten werden derzeit Trainingsdaten generiert. Parallel dazu wird eine Online-KI entwickelt, die in ein Edge Device integriert wird, um große Datenströme in Echtzeit zu verarbeiten und frühzeitig auf Prozessabweichungen reagieren zu können. Dabei wird die Integration von MQTT-Protokollen und Protobuf-Serialisierung untersucht, um eine schnelle und zuverlässige Datenübertragung zu gewährleisten.

Die entwickelten Systeme sollen in den nächsten Projektphasen an industriellen Demonstratoren von Airbus, Mercedes-Benz und Isar Aerospace validiert werden. Ziel ist eine signifikante Produktivitätssteigerung, die Reduzierung von Materialausschuss und die Verbesserung der Prozessstabilität. Schließlich sollen die Technologien in ein benutzerfreundliches Cockpit integriert werden, um den Anwender im Fertigungsprozess effizient zu unterstützen.





14 SenseAI



FAKTEN

PROJEKT

Entwicklung einer künstlichen Intelligenz für die In-situ-Qualitätskontrolle in der additiven Fertigung durch multimodale Prozessüberwachung

KOORDINATOR

Q2Web GmbH

PARTNER

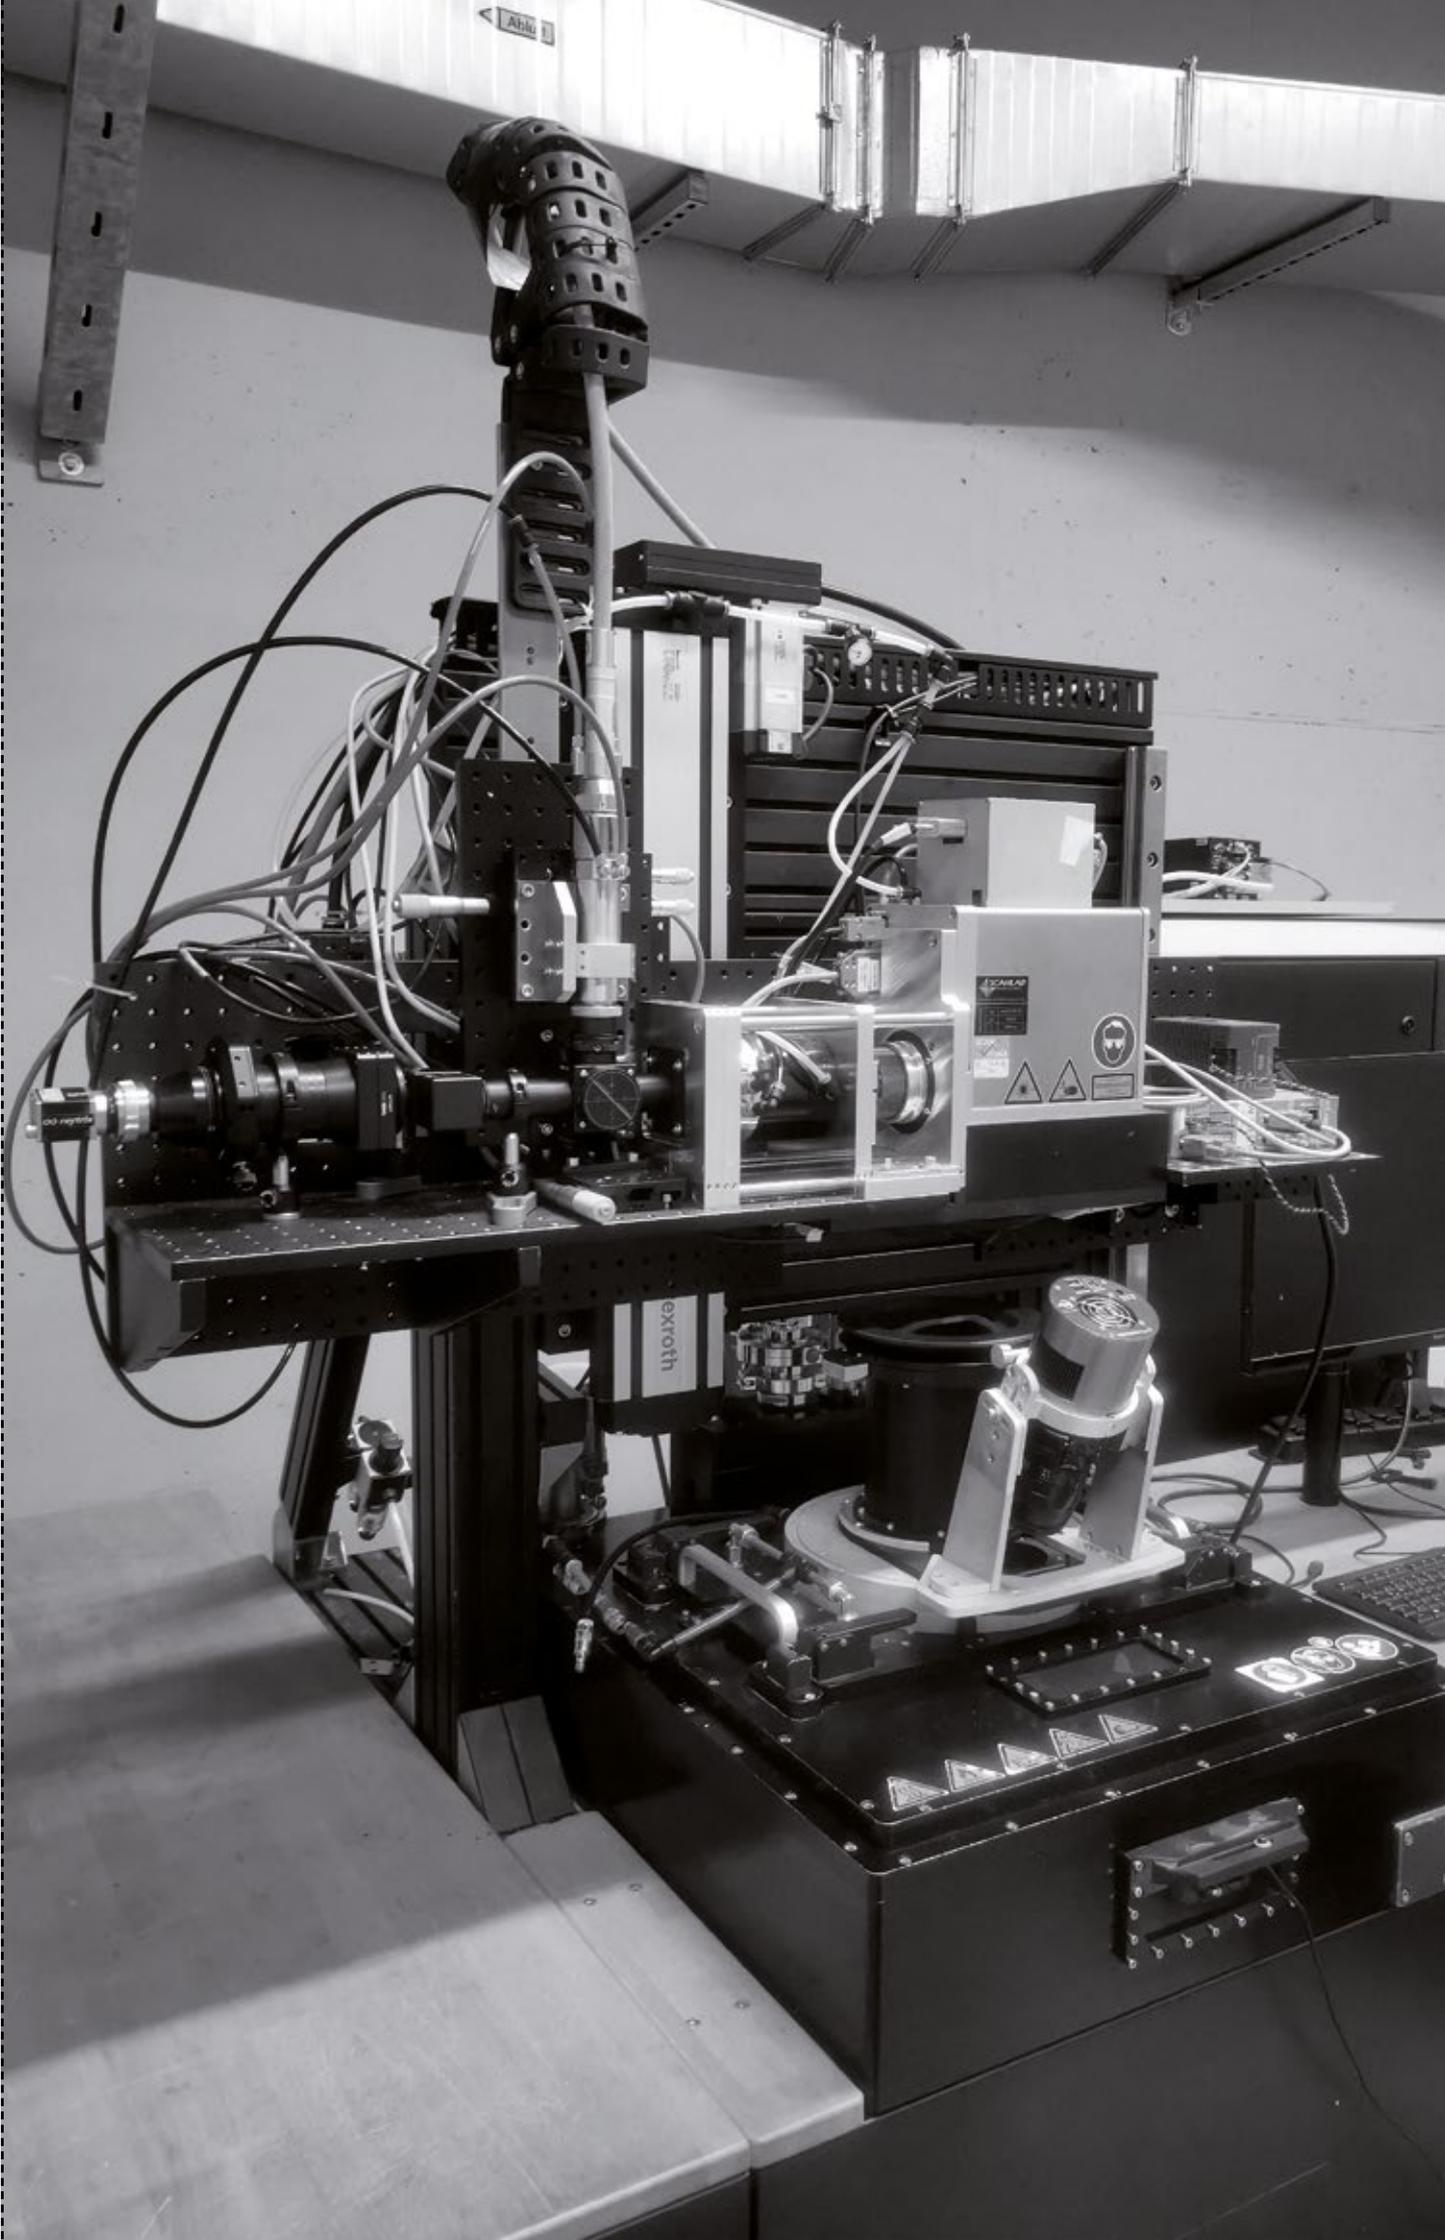
- Q2Web GmbH**
Entwicklung einer Prozessdatenbank, Datenfusion und Künstlichen Intelligenz für echtzeitfähige In-situ-Qualitätskontrolle
- Raytrix GmbH**
Entwicklung von In-situ-Prüftechnik auf Grundlage der hauseigenen Lichtfeldtechnologie
- ThetaScan GmbH**
Entwicklung von In-situ-Prüftechnik auf Grundlage der optischen Tomografie
- Fraunhofer IAPT**
Entwicklung einer Multisensor-Prozessüberwachung und einer Defektanalytik zur In-situ-Qualitätskontrolle im PBF-LB/M-Verfahren

Eine zentrale Herausforderung für die Etablierung von pulverbettbasierten additiven Verfahren in der industriellen Anwendung stellt die prozessbegleitende Qualitätskontrolle dar, die innerhalb des Produktionsprozesses zu Rückschlüssen auf die gefertigte Bauteilintegrität und -qualität befähigt. Bislang erfordern die Varianz der Bauteilqualität und der damit verbundene hohe Anteil an Ausschuss eine kostenintensive nachgelagerte Prüfung mittels Computertomografie (CT), welche die Wettbewerbsfähigkeit von Metall-3D-Druck-Verfahren entscheidend hemmen.

Ziel des Projektes war die Weiterentwicklung und Fusion mehrerer sich ergänzender Sensortechnologien zu einer Multisensorik, die zur Überwachung des 3D-Druck-Prozesses in eine Fertigungsanlage integriert wird. Mit dieser Demonstratoranlage lassen sich die vielseitigen qualitätsrelevanten Prozessmerkmale des additiven Herstellungsprozesses simultan erfassen und überwachen. Zur Sicherung, Verarbeitung und Interpretation der Sensordaten wurde ein KI-basiertes Datenbank- und Analysetool entwickelt, das eine automatisierte und orts aufgelöste Vorhersage von Bauteildefekten ermöglicht. Dadurch kann eine zuverlässige Aussage über die Bauteilqualität ohne Einsatz von teuren nachgelagerten CT-Untersuchungen getroffen werden.

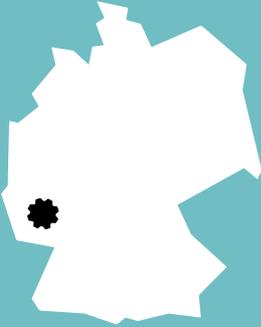
Die integrierte Multisensorik ermöglicht dabei die multimodale Erfassung der thermischen Prozesssignatur, die 3D-topografische Überwachung der Bauebene sowie die Aufnahme der Maschinendaten. Die erzeugten Messdaten wurden in einer Datenbankstruktur gespeichert und durch eine räumliche Zuordnung der Daten zu einem 3D-Prozessabbild fusioniert. Auf Grundlage der Daten wurde eine Künstliche Intelligenz zur automatischen Identifikation von Defekten entwickelt und trainiert. Für diese Feature-Erkennung bildeten CT-Prüfdaten gedruckter Probekörper die Grundlage und erlaubten die Zuordnung der Sensordaten zu realen Defekten.

Durch die Entwicklungen im Projekt wurde erreicht, dass die pulverbettbasierte additive Fertigung durch die gesteigerte und effizientere In-situ-Qualitätskontrolle tiefgreifender verstanden wird und eine neuer Ansatz für die Defektkorrelation verfolgt werden kann. Aufgrund der erzielten Ergebnisse sehen die Projektpartner in den realisierten Projektergebnissen die Möglichkeit, standardisierte Datensätze mit hoher Qualität und Zuverlässigkeit zu generieren, die den PBF-LB/M-Produktionsprozess räumlich und zeitlich vollständig abbilden.





15 TransKI



FAKTEN

PROJEKT

Beherrschung von Zerspanprozessen durch transferierbare Künstliche Intelligenz – Grundlage für Prozessverbesserungen und neue Geschäftsmodelle

KOORDINATOR

Mathias Schmidt, K.-H. Müller Präzisionswerkzeuge GmbH

PARTNER

- K.-H. Müller Präzisionswerkzeuge GmbH**
Entwicklung innovativer, KI-basierter Geschäftsmodelle
- RPTU Kaiserslautern Lehrstuhl für Fertigungstechnik und Betriebsorganisation**
Untersuchung der Zerspanmechanismen beim Bohren mittels parametrischer Modelle und ML
- Universität Stuttgart Institut für Werkzeugmaschinen (IfW)**
Entwicklung der Prozessvorsteuerung und der Schnittstelle zwischen ML-Modellen und Maschinensteuerung
- Empolis Information Management GmbH**
Entwicklung robuster ML-Modelle und Implementierung der Datenpipeline inklusive Assistenzsystem
- botek Präzisionsbohrtechnik GmbH**
Untersuchung der Transferierbarkeit der ML-Modelle auf industriell relevante Bohrprozesse
- Paul Horn GmbH**
Versuchsdurchführung und -auswertung beim Fräsen und Mitwirkung bei der Datenaufbereitung
- Robert Bosch GmbH**
Untersuchung der Transferierbarkeit der ML-Modelle auf industriell relevante Fräsprozesse

Das Verschleißverhalten von Zerspanungswerkzeugen variiert selbst unter konstanten Prozessrandbedingungen und beeinflusst maßgeblich die effektive Lebensdauer der Werkzeuge. Daher werden Werkzeuge in der Industrie oft zu früh gewechselt, um Ausfälle zu vermeiden und stabile Prozesse zu gewährleisten, was zu höheren Kosten und längeren Rüstzeiten führt. Tool Condition Monitoring (TCM) geht dieses Problem durch kontinuierliche Überwachung des Werkzeugzustands an. TCM mittels Machine Learning (ML) bietet dabei großes Potenzial, indem es eine effektive Überwachung und eine verbesserte Nutzung der Werkzeuglebensdauer ermöglicht. Allerdings können ML-Modelle für die Überwachung des Werkzeugzustands häufig nur anwendungsfallspezifisch eingesetzt werden und sind nicht ohne Weiteres auf z. B. variierende Prozessrandbedingungen, andere Maschinen oder andere Werkzeuge übertragbar.

TransKI zielt daher darauf ab, ML-Ansätze für Bohr- und Fräsanwendungen zu erforschen, die möglichst einfach und aufwandsarm auf neue Anwendungsfälle übertragbar sind. Um eine möglichst breite Anwendbarkeit der generierten ML-Modelle sicherzustellen, werden die Modelle in ein digitales Assistenzsystem integriert, das neben den ML-Modellen als Ausgangspunkt für innovative Geschäftsmodelle der beteiligten Industriepartner dienen kann.

Innerhalb des Projekts haben sich Ansätze zur Anomalieerkennung sowie ML-Modelle zur Bewertung des Remaining Useful Life (RUL) der Zerspanungswerkzeuge als zielführend erwiesen. Mithilfe der Anomalieerkennung können Abweichungen von normalen Betriebsmustern identifiziert werden, die oft auf Werkzeugverschleiß, Unregelmäßigkeiten oder Störungen im Prozess oder ein bevorstehendes Werkzeugversagen hinweisen. Die RUL-Bewertung gibt in Prozent (100 % bis 0 %) an, wie viel geschätzte Restnutzungsdauer verbleibt, bevor das Werkzeug ausfällt. Als Datenquelle für die Ansätze haben sich sowohl Daten aus der Steuerung der Maschine selbst als auch nachgerüstete Stromwandler zur Messung der Achs- und Spindelströme als zielführend erwiesen. Beide Ansätze dienen dazu, den richtigen Zeitpunkt für den Werkzeugwechsel zu identifizieren, um die Standzeit besser ausnutzen zu können.

Die entwickelten ML-Modelle dienen als Grundlage für ein plattformunabhängiges Assistenzsystem, das den Maschinenbediener bei der Wahl des Zeitpunktes für einen Werkzeugwechsel und mit Handlungsempfehlungen unterstützt. Um den Anforderungen der Maschinenbediener gerecht zu werden, wurde deren frühzeitige Einbindung in den nutzerzentrierten Entwicklungsprozess sichergestellt. Im Rahmen des Entwicklungsprozesses haben sich Visualisierungen für den Status der Anomalieerkennung und der RUL-Bewertung, die abhängig vom Werkzeugzustand unterstützend in Farben des Ampelsystems eingefärbt sind, sowie Dialogfenster mit Statusmeldungen als zielführend erwiesen.





WER UND WO?



Dr.-Ing.
LUKAS GRÜNDEL
ProKI Koordinierungsstelle



VINCENT LOHRMANN
ProKI Aachen



DANIEL HINZMANN
ProKI Berlin



SVEN VARCHMIN
ProKI Darmstadt



Hajo WIEMER
ProKI Dresden



DENNIS STOPPEL
ProKI Hannover



SEBASTIAN GERTH
ProKI Ilmenau



ALEXANDER PUCHTA
ProKI Karlsruhe



NILS THIELEN
ProKI Nürnberg

ProKI

AICoM



ANDREAS HOFFMANN
Lorenz Hoffmann GmbH



Dr. rer. nat.
VALENTINA KÖNIG
ModuleWorks GmbH



Dr.
STEFFEN LANG
Gühring KG



VOLKER MARQUARD
SynopSystems UG



GERHARD HAMMANN
TRUMPF Werkzeugmaschinen GmbH + Co. KG



JÜRGEN WOLL
DIEFFENBACHER GmbH
Maschinen- und Anlagenbau



BERND ZAPF
HELLER Maschinenfabrik GmbH



STEFAN LAMP
Arburg GmbH + Co. KG

Auto Lern



Dipl.-Ing.
HASAN SARAC
Automatic-Systeme Dreher GmbH



Dr.-Ing.
FRANK SCHNEIDER
Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e. V. Fraunhofer-Institut für Lasertechnik ILT



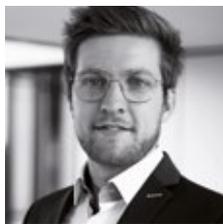
Prof. Dr.-Ing.
MICHAEL HEIZMANN
Karlsruher Institut für Technologie (KIT) Institut für Industrielle Informatik IIIIT

DIPOOL

GeMeKI



Dr.-Ing.
ALEXANDER ENGELS
aiXbrain GmbH



MANUEL BELKE
Werkzeugmaschinenlabor WZL der RWTH Aachen



HOSSEIN OMID BEIKI
Werkzeugmaschinenlabor WZL der RWTH Aachen



NINA PILLEN
YOUSE GmbH



OLIVER PETROVIC
Werkzeugmaschinenlabor WZL der RWTH Aachen



NILS KLASSEN
Werkzeugmaschinenlabor WZL der RWTH Aachen



RONJA WITT
Werkzeugmaschinenlabor WZL der RWTH Aachen



CHRIS SCHÖNEKEHS
Werkzeugmaschinenlabor WZL der RWTH Aachen

IRLEQuM

Kausal Assist



CARL WILLY MEHLING
Fraunhofer-Institut für Werkzeugmaschinen und Umformtechnik IWU



SVEN PIEPER
Fraunhofer-Institut für Werkzeugmaschinen und Umformtechnik IWU



FRANK SEIFERTH
SEITEC GmbH



CHRISTIAN STEIDLE
Schuster Maschinenbau GmbH



Prof. Dr.-Ing.
JÖRG KRÜGER
Institut für Werkzeug-
maschinen und Fabrik-
betrieb IWF
Technische Universität
Berlin



Dr.
JOACHIM GNAUK
PSI Metals GmbH



JOCHEN LUTZ
DiHeSys Digital Health
Systems GmbH



PhD
KEMAL LEVI
Relimetrics GmbH

KIKA-IPK



TOBIAS STEEGE
Fraunhofer-Institut für
Werkstoff- und Strahl-
technik



BRITTA HILT
IS Predict GmbH

MEDIUS



Prof. Dr.
GÜNTER BITSCH
Hochschule Reutlingen,
ESB Business School



Prof. Dr.
TIM STRAUB
Hochschule Reutlingen,
ESB Business School



DANIEL KIEFER
Hochschule Reutlingen,
ESB Business School



FLORIAN GRIMM
Hochschule Reutlingen,
ESB Business School



**JACQUELINE
HÖLLIG**
FZI Forschungszentrum
Informatik

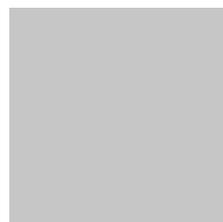
MetaLearn



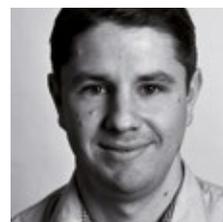
Dr.
OLIVER TIEDJE
Fraunhofer-Institut für
Produktionstechnik und
Automatisierung IPA



Dr.
MEIKO HECKER
AOM Systems GmbH



Dr.
RÜDIGER MÄSTLE
Helmut Fischer GmbH
Institut für Elektronik und
Messtechnik



JOCHEN RIESER
b+m surface systems
GmbH

pAInt-Behaviour



WIEBKE ZENN
TRUMPF Werkzeug-
maschinen SE & Co. KG



**SEBASTIAN
ROEDING**
Wittenstein SE



KAMAL GALRANI
Tvarit GmbH



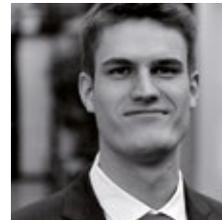
**JONATHAN
MILLITZER**
Fraunhofer-Institut für
Betriebsfestigkeit und
Systemzuverlässigkeit

ProInect

ProSLAM



Dr.
JAN BREMER
BCT-Steuerung und
DV-Systeme GmbH



**CEDRIC
HAUSCHOPP**
Fraunhofer-Institut für
Lasertechnik ILT



DIETER WEILER
Q2Web GmbH



ARNE ERDMANN
Raytrix GmbH



FRANK WEISSBUCH
ThetaScan GmbH



DENNIS JUTKUH
Fraunhofer-Einrichtung
für Additive Produktions-
technologien IAPT

SenseAI

TransKI



MATHIAS SCHMIDT
K.-H. Müller Präzisions-
werkzeuge GmbH



Prof. Dr.-Ing.
JAN C. AURICH
Rheinland-Pfälzische
Technische Universität
Kaiserslautern-Landau/
Lehrstuhl für Fertigungs-
technik und Betriebsorga-
nisation (FBK)



Univ.-Prof. Dr.-Ing. Dr. h. c.
**HANS-CHRISTIAN
MÖHRING**
Universität Stuttgart/
Institut für Werkzeug-
maschinen



IMPRESSUM

HERAUSGEBER

Lukas Gründel, Werkzeugmaschinenlabor WZL der RWTH Aachen, ProKI Koordinierungsstelle
Christian Brecher, Werkzeugmaschinenlabor WZL der RWTH Aachen, ProKI Koordinierungsstelle
Werner Herfs, Werkzeugmaschinenlabor WZL der RWTH Aachen, ProKI Aachen
Vincent Lohrmann, Werkzeugmaschinenlabor WZL der RWTH Aachen, ProKI Aachen
Daniel Hinzmann, Institut für Werkzeugmaschinen und Fabrikbetrieb, ProKI Berlin
Sven Varchmin, Institut für Produktionstechnik und Umformmaschinen, ProKI Darmstadt
Hajo Wiemer, Institut für Mechatronischen Maschinenbau, ProKI Dresden
Dennis Stoppel, Institut für Fertigungstechnik und Werkzeugmaschinen, ProKI Hannover
Sebastian Gerth, TU Ilmenau, ProKI Ilmenau
Alexander Puchta, wbk Institut für Produktionstechnik, ProKI Karlsruhe
Nils Thielen, Lehrstuhl für Fertigungsautomatisierung und Produktionssystematik, ProKI Nürnberg
Andreas Hoffmann, Lorenz Hoffmann GmbH, AICoM
Valentina König, Module Works GmbH, AICoM
Steffen Lang, Gühring KG, AICoM
Volker Marquard, SynopSystems UG, AICoM
Gerhard Hamann, TRUMPF Werkzeugmaschinen GmbH + Co. KG, AutoLern
Jürgen Woll, Dieffenbacher GmbH Maschinen- und Anlagenbau, AutoLern
Bernd Zapf, HELLER Maschinenfabrik GmbH, AutoLern
Stefan Lamp, Arburg GmbH + Co. KG, AutoLern
Hasan Sarac, Automatic-Systeme Dreher GmbH, DIPOOL
Frank Schneider, Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V. Fraunhofer-Institut für Lasertechnik ILT, DIPOOL
Michael Heizmann, Karlsruher Institut für Technologie (KIT) Institut für Industrielle Informationstechnik IIIT, DIPOOL
Alexander Engels, aiXbrain GmbH, GeMeKI
Manuel Belke, Werkzeugmaschinenlabor WZL der RWTH Aachen, GeMeKI
Hossein Omid Beiki, Werkzeugmaschinenlabor WZL der RWTH Aachen, GeMeKI
Nina Pillen, YOUSE GmbH, GeMeKI
Oliver Petrovic, Werkzeugmaschinenlabor WZL der RWTH Aachen, GeMeKI
Nils Klases, Werkzeugmaschinenlabor WZL der RWTH Aachen, IRLEQuM
Ronja Witt, Werkzeugmaschinenlabor WZL der RWTH Aachen, IRLEQuM
Chris Schönekehs, Werkzeugmaschinenlabor WZL der RWTH Aachen, IRLEQuM
Carls Willy Mehling, Fraunhofer-Institut für Werkzeugmaschinen und Umformtechnik IWU, KausaLAssist
Sven Pieper, Fraunhofer-Institut für Werkzeugmaschinen und Umformtechnik IWU, KausaLAssist
Frank Seiferth, Unternehmen/Institut: SEITEC GmbH, KausaLAssist
Christian Steidle, Schuster Maschinenbau GmbH, KausaLAssist
Jörg Krüger, Fachgebietsleiter Industrielle Automatisierungstechnik
Institut für Werkzeugmaschinen und Fabrikbetrieb IWF
Technische Universität Berlin, KIKA-IPK
Joachim Gnauk, PSI Metals GmbH, KIKA-IPK
Jochen Lutz, DiHeSys Digital Health Systems GmbH, KIKA-IPK
Kemal Levi, Relimetrics GmbH, KIKA-IPK
Tobias Steege, Fraunhofer-Institut für Werkstoff- und Strahltechnik, MEDIUS
Britta Hilt, IS Predict GmbH, MEDIUS
Günter Bitsch, Hochschule Reutlingen, ESB Business School, MetaLearn
Tim Straub, Hochschule Reutlingen, ESB Business School, MetaLearn
Daniel Kiefer, Hochschule Reutlingen, ESB Business School, MetaLearn
Florian Grimm, Hochschule Reutlingen, ESB Business School, MetaLearn
Jacqueline Höllig, FZI Forschungszentrum Informatik, MetaLearn
Oliver Tiedje, Fraunhofer IPA, pAInt-Behaviour
Meiko Hecker, AOM Systems GmbH, pAInt-Behaviour
Rüdiger Mästle, Helmut Fischer GmbH Institut für Elektronik und Messtechnik, pAInt-Behaviour
Jochen Rieser, b+m surface systems GmbH, pAInt-Behaviour
Wiebke Zenn, TRUMPF Werkzeugmaschinen SE & Co. KG, ProKInect
Sebastian Roeding, Wittenstein SE, ProKInect
Kamal Galrani, Tvarit GmbH, ProKInect
Jonathan Millitzer, Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit, ProKInect
Jan Bremer, BCT-Steuerung und DV-Systeme GmbH, ProSLAM
Cedric Hauschopp, Fraunhofer-Institut für Lasertechnik ILT, ProSLAM
Dieter Weiler, Q2Web GmbH, SenseAI
Arne Erdmann, Raytrix GmbH, SenseAI
Frank Weissbuch, ThetaScan GmbH, SenseAI
Dennis Jutkuhn, Fraunhofer IPT, SenseAI
Mathias Schmidt, K.-H. Müller Präzisionswerkzeuge GmbH, TransKI
Prof. Dr.-Ing. Jan C. Aurich, Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau / Lehrstuhl für Fertigungstechnik und Betriebsorganisation (FBK), TransKI
Hans-Christian Möhring, Universität Stuttgart / Institut für Werkzeugmaschinen, TransKI



REDAKTION

Lehrstuhl für Werkzeugmaschinen
Werkzeugmaschinenlabor WZL der RWTH Aachen University
Steinbachstraße 19
52074 Aachen

www.wzl.rwth-aachen.de

FÖRDERHINWEIS

Der Projektatlas wird in den Fördermaßnahmen „Demonstrations- und Transfernetzwerk KI in der Produktion (ProKI-Netz)“ und „Lernende Produktionstechnik - Einsatz Künstlicher Intelligenz (KI) in der Produktion (ProLern)“ durch das Bundesministerium für Bildung und Forschung (BMBF) im Programm „Zukunft der Wertschöpfung - Forschung zu Produktion, Dienstleistung und Arbeit“ gefördert und vom Projektträger Karlsruhe (PTKA) betreut.

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren. Sofern nicht durch die Nennung sowohl der weiblichen als auch der männlichen Form gekennzeichnet, werden Frauen und Männer gleichermaßen angesprochen.

KONZEPT UND GESTALTUNG

wesentlich.com
Montzenerstr. 56, 4710 Lontzen, Belgien

SCHRIFTEN

Delicious
Geometric Slabserif 703 BT
Interstate

VERWENDETES PAPIER

Maxi Offset holzfrei weiß

DRUCK

Image Druck & Medien

FOTOS/BILDMATERIAL

Cover: wesentlich.com unter Verwendung einer Open Source Illustration von google deepmind

Innenteil: wesentlich. unter Verwendung weiterer Datenvisualisierungen von google deepmind, Material der Projektbeteiligten
September 2024

© Copyright: Alle Rechte vorbehalten. Kein Teil dieser Broschüre darf ohne schriftliche Genehmigung des Herausgebers vervielfältigt oder verbreitet werden. Unter dieses Verbot fallen insbesondere die gewerbliche Vervielfältigung bei Kopie, die Aufnahme in elektronische Datenbanken und die Vervielfältigung auf digitale Ben Datenträgern.

MEDIENPARTNER

VDI nachrichten - ein Angebot des VDI Verlags Düsseldorf

ISBN 13:

978-3-18-990141-2

E-ISBN:

978-3-18-990142-9



PROJEKTATLAS

Der Projektatlas „Künstliche Intelligenz in der Produktion“ - ein unverzichtbares Werk für alle, die sich mit den Chancen und Herausforderungen von KI für die Produktion der Zukunft auseinandersetzen möchten. Neben aktuellen Forschungsergebnissen wird ein umfassender Leitfaden zur Einführung von KI in Unternehmen geboten, der zentrale Themen wie den strategischen und wirtschaftlichen Einsatz und die Förderung der Akzeptanz bei den Mitarbeitenden fokussiert. Darauf folgen praxisnahe Best-Practices, die Einblicke in die notwendige Digitalisierung, das Datenmanagement, spezifische KI-Methoden und auch hier in das Zusammenspiel zwischen Mensch und KI geben.

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung