

Leitfaden Künstliche Intelligenz – Potenziale und Umsetzungen im Mittelstand



in Kooperation mit



Gefördert durch

Bayerisches Staatsministerium für
Wirtschaft, Landesentwicklung und Energie



Inhalt

Vorwort des Staatsministers Hubert Aiwanger, MdL	4
Die Chancen der Digitalisierung nutzen	
Vorwort der Forschungsinstitute	5
Vorwort des VDMA	6
Künstliche Intelligenz im bayerischen Mittelstand	
Management Summary	7
Künstliche Intelligenz – alte Versprechen oder neue Möglichkeiten?	8
Aufbau des Leitfadens	10
Die wichtigsten Begriffe	12
Fähigkeiten und industrielle Anwendung von Künstlicher Intelligenz	14
KI-Potenziale im eigenen Unternehmen identifizieren	30
KI-Projekte erfolgreich umsetzen	35
KI-Projekte dokumentieren	47
Zusammenfassung und Ausblick	51
Projektpartner / Impressum	52
Weitere Ressourcen	



Die Chancen der Digitalisierung nutzen



Staatsminister
Hubert Aiwanger
(MDL)

**Sehr geehrte Leserinnen,
Sehr geehrte Leser,**

die Digitalisierung verändert nachhaltig die Art und Weise, wie wir leben und arbeiten. Eine der Schlüsseltechnologien dieser Veränderungen stellt die Künstliche Intelligenz dar.

Die Schaffung von Mehrwerten aus großen Datensätzen – den „Big Data“ – ist von zentraler Bedeutung für die Entwicklung neuer, innovativer Geschäftsmodelle. Ihre Anwendbarkeit bietet gerade im Verarbeitenden Gewerbe ein enormes Innovationspotenzial. Für Bayern ist – mit einem Anteil des Verarbeitenden Gewerbes von 25 % an der gesamten Bruttowertschöpfung – eine erfolgreiche Transformation daher von existenzieller Bedeutung für Wohlstand, Wachstum und Innovationskraft. Das Potenzial dieser Technologien, egal ob in Konstruktion, Vertrieb oder der vorausschauenden Wartung, ist riesig. So können etwa Anlagen- und Maschinenbauer bei der Qualitätskontrolle auf KI-gesteuerte Bilderkennung zurückgreifen oder lernfähige Algorithmen anwenden, die aus Daten wie Hitze, Lärm, Schwingungen oder Stromverbrauch den Verschleiß von Maschinen schlussfolgern. Zentrales Stichwort ist hier die Predictive Maintenance, die vorausschauende Instandhaltung.

Erfreulicherweise halten Anwendungen mit Künstlicher Intelligenz schon heute in immer mehr Bereichen der Industrie Einzug. Gleichzeitig sind die Anforderungen gerade an die kleinen und mittleren Unternehmen nach wie vor groß. Vorhandene Maschinen sind meist in komplexe Produktionsabläufe eingebunden. Der Einsatz von Künstlicher Intelligenz erfordert daher, neben oftmals erheblichen Investitionen, auch einen raschen Erwerb der Qualifikation und eine Umstellung der Organisation in den Unternehmen. Hierzu muss die Belegschaft eng

mit eingebunden werden, denn nur wenn Veränderungen von Mitarbeiterinnen und Mitarbeitern angenommen werden, haben sie langfristigen Erfolg.

Diesen Transformationsprozess zu begleiten und zu stärken, ist ausdrückliches Ziel der Bayerischen Staatsregierung. Bayern soll auch weiterhin ein attraktiver Wirtschafts- sowie Innovationsstandort sein. Im Bereich Industrie 4.0 stellen die industrienahen Kooperationsprojekte einen zentralen Baustein der bayerischen Förderpolitik dar. Mit dem vom Bayerischen Staatsministerium für Wirtschaft, Landesentwicklung und Energie geförderten Projekt „Industrie 4.0 – Daten basierter Wandel im Mittelstand“ hat der VDMA Bayern eine zentrale Anlaufstelle geschaffen, bei der sich bayerische Unternehmen über neue Technologien und Anwendungen aus dem Bereich Industrie 4.0 informieren, insbesondere aber mit anderen Unternehmen über die gemachten Erfahrungen auf regionaler und überregionaler Ebene austauschen können. Mit dem „Leitfaden Künstliche Intelligenz – Potenziale und Umsetzungen im Mittelstand“ bietet der VDMA Bayern nun eine weitere wichtige Handlungsanleitung zur Stärkung des Transformationsprozesses der Digitalisierung und der Anwendbarkeit von Künstlicher Intelligenz im bayerischen Mittelstand. Hierfür möchte ich mich im Namen der Bayerischen Staatsregierung ganz herzlich bedanken!

Ich bin überzeugt, dass dieser Leitfaden Sie, liebe Leserinnen und Leser, dabei unterstützen kann, Potenziale für Künstliche Intelligenz in Ihrem Unternehmen zu identifizieren und Ihnen die notwendigen Schritte für die Umsetzung zu veranschaulichen.

In diesem Sinne wünsche ich Ihnen alles Gute beim Ergreifen dieser Chancen!


Staatsminister Hubert Aiwanger, MDL
Stv. Ministerpräsident



Gunther Reinhart



Michael F. Zäh

Künstliche Intelligenz (KI) als wissenschaftliches Fachgebiet existiert seit Mitte der 1950er Jahre. Da jedoch viele KI-Technologien zur Datenerfassung und -verarbeitung extrem leistungsfähige Rechner, große Datenspeicher

und schnelle Netzwerke benötigen, dauerte es Jahrzehnte, bis die ersten Anwendungen den Weg in die wirtschaftliche Nutzung und damit in die produzierende Industrie gefunden haben.

Der exponentielle Fortschritt der Rechnertechnik in den vergangenen zehn Jahren hat es nun ermöglicht, immer leistungsfähigere Algorithmen zu entwickeln, die für spezifische Aufgaben zunehmend mit menschlichen Fähigkeiten mithalten können oder diese sogar schon übertreffen. Dies gilt insbesondere dann, wenn bereits große Datenmengen verfügbar sind, die durch uns Menschen nicht mehr effizient gesichtet und analysiert werden können. Durch die beeindruckenden Entwicklungen im Bereich der sogenannten Industrie 4.0., die uns eine umfassende Datensammlung aus unseren Produktionsanlagen erlauben, erlangen die Fähigkeiten der Informationsverarbeitung immer größere Bedeutung.

Mit Deutschland als drittgrößtem Maschinen- und Anlagenproduzenten weltweit gilt der Maschinen- und Anlagenbau hierzulande als ein führender Export- und Innovationssektor. Die stark mittelständisch geprägte Branche ist das Rückgrat der deutschen Industrie, spiegelt deren gesamtes Spektrum an Leistungsfähigkeit wider

und ist ein wichtiger Innovationstreiber in Bereichen wie Digitalisierung der Produktion, ressourcenschonende Produktion und Energieeffizienz. Diese führende Position ist auch im Hinblick auf die neue technologische Innovation, nämlich die Umsetzung der KI-Technologie in der Produktion, zu bewahren. Die Anwendung der KI-Technologie hat bereits einige Perspektiven aufgezeigt, um die Effizienz und Qualität zu steigern, die Mitarbeitenden bei der täglichen Arbeit zu unterstützen oder sogar neue Handlungsfelder zu erschließen. Zudem drängen mit den großen IT-Konzernen auch neue Wettbewerber auf den Markt. Der Einbindung der Künstlichen Intelligenz in moderne Maschinen und Anlagen kommt damit in näherer Zukunft eine fundamentale Bedeutung zu.

Aufgrund der teils anspruchsvollen Entwicklung der zugrunde liegenden Algorithmen stellen die Identifikation geeigneter Einstiegslösungen und deren Umsetzung viele Maschinen- und Anlagenhersteller jedoch vor besondere Herausforderungen. Die deutschen Maschinen- und Anlagenbauer verfügen über jahrzehntelang aufgebaute Erfahrungen und technisches Know-how. Kombiniert mit den modernen Technologien von Industrie 4.0 haben sie die idealen Voraussetzungen, um Methoden der Künstlichen Intelligenz gewinnbringend einzusetzen.

Der vorliegende Leitfaden dient als Orientierungshilfe, um diese Voraussetzungen gezielt für die Anwendung der KI-Technologie zu nutzen, individuell geeignete Potenziale zu identifizieren, KI-Projekte erfolgreich durchzuführen und die Methoden der Künstlichen Intelligenz wirtschaftlich einsetzbar zu gestalten.

Prof. Dr.-Ing. Gunther Reinhart

Fraunhofer-Institut für Gießerei-,
Composite- und Verarbeitungstechnik
(IGCV)

Prof. Dr.-Ing. Michael F. Zäh

Institut für Werkzeugmaschinen und
Betriebswissenschaften (iwmb)
Technische Universität München

Künstliche Intelligenz im bayerischen Mittelstand



Elgar Straub



Michael Schalk

Künstliche Intelligenz (KI) beherrscht mittlerweile nicht nur unseren Alltag, sondern ist auch aus der Industrie nicht mehr wegzudenken. Die Potenziale sind den meisten Unternehmen bekannt und trotzdem gestalten sich die ersten Schritte in konkreten Projekten für viele noch als Herausforderung. Gerade für den Mittelstand im Maschinen- und Anlagenbau ist es oftmals nicht einfach, Projekte im Bereich der Künstlichen Intelligenz zur Verbesserung von Prozessen in Unternehmen, aber auch für neue Geschäftsmodelle zu identifizieren und danach in die Umsetzung zu kommen.

Den Herausforderungen gilt es sich zu stellen, damit KI kein Thema für einzelne Unternehmen bleibt, sondern in die DNA des breit aufgestellten Mittelstands übergeht. Wichtig ist es dabei nicht zu vergessen, auch im Kleinen Potenziale zu erkennen und diese umzusetzen. KI soll kein Buzzword bleiben, sondern soll sich als fester Bestandteil im Unternehmensalltag etablieren und die Wettbewerbsfähigkeit des bayerischen und deutschen Mittelstands erhalten und sogar ausbauen.

Der vorliegende Leitfaden hat zum Ziel, ein gemeinsames Verständnis zu Künstlicher Intelligenz und deren Umsetzung im Unternehmen zu schaffen. Er soll praxisorientiert dabei helfen, vielversprechende KI-Projekte im eigenen Betrieb zu erkennen.

Der Leitfaden ist im Rahmen des Projekts „Industrie 4.0 – Daten basierter Wandel im Mittelstand“, das vom Bayerischen Staatsministerium für Wirtschaft, Landesentwicklung und Energie gefördert ist, entstanden. Der Dank für die Ausarbeitung gilt der Fraunhofer Gesellschaft und der Technischen Universität München sowie selbstverständlich den vielen Unternehmen, die im Rahmen einer Projektgruppe diesen Leitfaden gestaltet haben.



Darüber hinaus können Sie unter folgendem QR-Code weitere zahlreiche Infos rund um das Thema KI finden.

Wir wünschen Ihnen eine spannende Lektüre!

Elgar Straub
Geschäftsführer VDMA Bayern

Michael Schalk
Projektmanager Industrie 4.0 Bayern

Management Summary

Für die deutsche Investitionsgüterindustrie ergeben sich durch Ansätze der Künstlichen Intelligenz (KI) neue Möglichkeiten, unternehmensinterne Prozesse zu optimieren oder neue Geschäftsmodelle zu entwickeln. Doch so vielfältig die Anwendungsmöglichkeiten sind, so schwierig ist es auch, die ersten Schritte zu wagen und gewinnbringende Projekte zu identifizieren und umzusetzen.

Ziel des Leitfadens Künstliche Intelligenz ist es, deutsche Unternehmen bei diesen ersten Schritten zu unterstützen. Hierzu wurden innerhalb der Projektgruppe „Künstliche Intelligenz“ des VDMA Bayern die Erfahrungen von KI-Expert*innen und Unternehmen, welche diese ersten Schritte bereits gegangen sind, gesammelt. In den folgenden Kapiteln sind die Ergebnisse zusammengetragen, um Unternehmen ein Werkzeug zur Verfügung zu stellen, das ihnen erlaubt, sich mit diesem noch sehr abstrakten und komplexen Thema auseinanderzusetzen.

Zu Beginn sollen eine kurze Einführung in die Begriffswelt und eine repräsentative Sammlung konkreter Anwendungsfälle klären, was sich hinter Künstlicher Intelligenz verbirgt und welche neuen Möglichkeiten sich für Unternehmen eröffnen. Anschließend werden die wesentlichen Schritte aufgezeigt, um Potenziale für den Einsatz von KI im eigenen Unternehmen zu identifizieren und entsprechende Projekte gemeinsam mit externen Expert*innen oder zukünftig auch selbstständig umzusetzen.

Die Zielgruppe des Leitfadens sind Entscheidungsträger*innen, welche die Chancen und Risiken von KI abschätzen möchten, wobei auf den Erfahrungen der im Folgenden genannten Unternehmen aufgebaut werden kann:

- asimovero.AI
- Baumüller Anlagen-Systemtechnik GmbH & Co. KG
- Chr. Mayr GmbH + Co. KG
- DEPRAG SCHULZ GMBH u. CO.
- iteratec GmbH
- Kiefel GmbH
- KraussMaffei Technologies GmbH
- Martin GmbH für Umwelt- und Energietechnik
- MVTec Software GmbH
- Siemens AG
- Technologisches Institut für angewandte Künstliche Intelligenz GmbH
- The MathWorks GmbH
- XITASO GmbH

Der vorliegende Leitfaden ist das Ergebnis eines intensiven Austauschs innerhalb der Projektgruppe „Künstliche Intelligenz“, deren Mitglieder in mehreren Arbeitstreffen die im Folgenden behandelten Themen, Herausforderungen aus vergangenen Projekten sowie Lösungsansätze diskutiert haben.

Künstliche Intelligenz – alte Versprechen oder neue Möglichkeiten?

Im Zuge der allgegenwärtigen Digitalisierung von Maschinen- und Anlagenstrukturen bietet eine stetig wachsende Daten- und Informationsfülle die Möglichkeit, das bestehende System- und Prozessverständnis zu erweitern. Oft übersteigt die Datenmenge jedoch die Leistungsfähigkeit des Menschen, die Informationen semantisch sinnhaft zu ordnen, deduktive und induktive Schlussfolgerungen abzuleiten sowie die Informationen gewinnbringend zur Lösung akuter Problemstellungen oder im Sinne gänzlich neuer Geschäftsmodelle einzusetzen.

Eine Vielzahl neuer, alltagstauglicher Tools, wie beispielsweise die digitalen Assistenten Siri, Cortana und Alexa, die maschinelle Übersetzung von DeepL oder die adaptive Routenführung von Google Maps zeigen, dass insbesondere Methoden der Künstlichen Intelligenz (KI) komplexe Zusammenhänge und Relationen in Datensätzen automatisiert identifizieren, verarbeiten und verwerten können. Die zugrunde liegenden Algorithmen sind in der Lage, eigenständig Lösungen zur Identifikation dieser Zusammenhänge zu suchen sowie den Lösungsweg autonom zu planen und zu optimieren. Im spielerischen Kräftemessen von menschlicher und Künstlicher Intelligenz beweisen IBMs Watson und DeepMinds AlphaGo Zero eindrucksvoll, dass die digitalen Systeme auf Veränderungen ihrer Umwelt geeignet reagieren und die eigene Strategie selbstständig und weitsichtig anpassen können.

Intelligente Systeme – gestern und heute

Die Abgrenzung, wann ein System als Künstliche Intelligenz bezeichnet wird, kann nicht trennscharf getroffen werden. Eine gängige Definition der Künstlichen Intelligenz wurde bereits 1983 von Elaine Rich prägnant formuliert:

Künstliche Intelligenz ist die Untersuchung dessen, wie man Computer dazu bringt, Dinge zu tun, bei denen die Menschen im Moment besser sind.

Die Erforschung der Künstlichen Intelligenz datiert zurück bis in die 1930er Jahre. Große Bekanntheit erlangten die Entwicklungen in diesem Fachgebiet erstmals in den späten 1940er und 1950er Jahren durch aufsehenerregende Forschungsarbeiten von Alan Turing und Johann von Neumann. Die Grenzen der damaligen Algorithmen und künstlicher neuronaler Netzstrukturen traten Anfang der 1970er Jahre zutage, was heute oft als der **erste KI-Winter** bezeichnet wird. In den 1980er Jahren beflügelten sogenannte Expertensysteme die Entwicklungen. Anfang der 1990er Jahre verloren die Expertensysteme durch ihre enorme Komplexität an Popularität, was üblicherweise als der **zweite KI-Winter** bezeichnet wird.

Durch die aktuellen Errungenschaften moderner, maschineller Lernverfahren auf Basis äußerst kostengünstig verfügbarer Rechenleistung werden derzeit wieder vermehrt enorme Hoffnungen und Erwartungen in unterschiedlichste Anwendungsfelder der Künstlichen Intelligenz gesetzt.

Wozu dient der Leitfaden?

Die Identifikation geeigneter Problemstellungen, die softwaretechnische Implementierung und die kontinuierliche Nutzung der Algorithmen der Künstlichen Intelligenz stellen Unternehmen vor technische und insbesondere organisatorische Herausforderungen.

Der folgende Leitfaden zum Themenbereich Künstliche Intelligenz soll Entscheidungsträger*innen befähigen, vielversprechende Problemstellungen zum Einsatz moderner Algorithmen zu identifizieren, geeignete Lösungskonzepte selbstständig zu erarbeiten und Chancen und Risiken qualifiziert beurteilen zu können. Der Leitfaden adressiert neben den technischen Umsetzungsmöglichkeiten insbesondere die organisatorischen Herausforderungen, die mit der Einführung von Methoden der Künstlichen Intelligenz einhergehen.

Aufbau des Leitfadens

Wie im vorangegangenen Kapitel dargestellt, umfasst der Begriff **Künstliche Intelligenz** (KI) ein breites und auf den ersten Blick unübersichtliches Feld. Der vorliegende Leitfaden vermittelt daher einerseits Grundlagenwissen zur industriellen Anwendung von KI-Methoden, andererseits wird eine anschauliche Schritt-für-Schritt-Hilfestellung für die Planung und Durchführung eines ersten KI-Projekts gegeben.

Die Grundlagen: Was ist KI? Was kann KI?

Um den Leser*innen den Einstieg in die Thematik zu erleichtern, stellt das folgende Kapitel kurz wesentliche Begrifflichkeiten vor. Das daran anschließende Kapitel **Fähigkeiten und industrielle Anwendung von KI** dient dazu, die Möglichkeiten von KI-Werkzeugen und die daraus entstehenden Mehrwerte für Unternehmen zu veranschaulichen. Ein Überblick über Anwendungen in verschiedenen Unternehmensbereichen und eine Sammlung konkreter Anwendungsfälle schaffen eine Grundlage für die Identifikation von Potenzialen im eigenen Unternehmen.

Schritt für Schritt im ersten KI-Projekt

Im Anschluss an die Anwendungsbeispiele wird anhand eines exemplarischen Vorgehens Schritt für Schritt erklärt, wie KI-Potenziale im Unternehmen gefunden und KI-Projekte strukturiert umgesetzt werden können.

Im Kapitel **KI-Potenziale im eigenen Unternehmen identifizieren** lernen die Leser*innen, wie KI-Potenziale systematisch im Rahmen von Workshops identifiziert und auf ihren Nutzen sowie ihre Umsetzbarkeit hin bewertet werden können (siehe Abbildung 1). Zu diesem Zweck geht der Leitfaden an dieser Stelle auch auf die wesentlichen Aspekte zur Beurteilung der verfügbaren Datenbasis ein.




Abbildung 1: Das Kapitel **KI-Potenziale im eigenen Unternehmen identifizieren** gibt Hilfestellungen für Potenzialworkshops




Abbildung 2: Das Kapitel **KI-Projekte erfolgreich umsetzen** geht ausführlich auf die wichtigsten Phasen eines KI-Projekts ein

Das Kapitel **KI-Projekte erfolgreich umsetzen** stellt grundlegende Projektphasen in der Umsetzung von KI-Anwendungen dar – vom Projektstart bis zum laufenden Betrieb der entwickelten KI-Lösung (siehe Abbildung 2). Leitfragen bieten eine Hilfestellung, welche Expertise in den jeweiligen Phasen notwendig ist und welche Themen berücksichtigt werden sollten.

Ist ein Projekt abgeschlossen, gilt es, zurückzublicken und gewonnene Erkenntnisse zu sichern, Erfahrungen auszutauschen sowie einen Blick nach vorn zu wagen und nächste mögliche Schritte anzugehen. Das Kapitel **Dokumentation von KI-Projekten** stellt dazu eine Projekt-Kurzdokumentation zur Reflexion und Kommunikation von Projektergebnissen bereit (siehe Abbildung 3).

VDMA – Leitfaden Künstliche Intelligenz Vorlage Projektdokumentation

Projektname

Projektlaufzeit

von bis

Projektbudget

..... €

Besetzte Projektkrollen

- Projektleiter*in
- Technologie-Expert*in
- KI-Expert*in
- ML-ops-Ingenieur*in

Ausgangssituation und Zielsetzung

Siehe Beschreibung der Ausgangssituation, Motivation und Zielsetzung

Durchführung

Siehe Beschreibung des Projektfortschritts anhand der Umsetzungsmaßnahmen für jede Phase im Laufe des Projekts

Ergebnisse

Siehe Beschreibung der Ergebnisse, Rückblick auf die Projektziele sowie Bewertung des Nubens, der durch das Projekt erreicht wurde

Einordnung des Projekts

	Identifizierung (Anforderung & Problem)	Problemlösung (Anforderung & Problem)	Implementierung (Anforderung & Problem)	Validierung (Anforderung & Problem)	Deployment (Anforderung & Problem)	Monitoring (Anforderung & Problem)	Wartung (Anforderung & Problem)
Beschreibung							
Umfeld/Anforderungen							
Problemlösung							

Ausgefülltes Business Model Canvas

Gewonnene Erkenntnisse

Siehe Beschreibung der Herausforderungen, der daraus gewonnenen Erkenntnisse sowie des Verbesserungspotenzials im Hinblick auf das Projekt

Zusammenfassung und Ausblick

Zusammenfassung des Projekts in Fakten und Zahlen und Beschreibung möglicher nächster Schritte (ggf. Folgerungen)

VDMA TUM Fraunhofer

Abbildung 3: Zur Kommunikation von Projekten beinhaltet das Kapitel **Dokumentation von KI-Projekten** die Vorlage für eine Kurzdokumentation

Die wichtigsten Begriffe

Bevor erläutert wird, wie Projekte im Bereich der Künstlichen Intelligenz (KI) zur Verbesserung von Prozessen in Unternehmen identifiziert und umgesetzt werden können, ist es wichtig, relevante Begrifflichkeiten zu definieren und ein grundlegendes Verständnis zu diesen zu schaffen. Der Begriff **Künstliche Intelligenz** bezieht sich auf Maschinen, die menschliche kognitive Fähigkeiten nachahmen, die etwa Sprache und strategisches Denken erfordern. KI-Anwendungen ermöglichen damit Maschinen, Aufgaben zu übernehmen, die bisher nur von Menschen ausgeführt werden konnten.

Der Begriff **Maschinelles Lernen** (ML) wird häufig synonym zu KI verwendet. Jedoch beschreibt er eine eigenständige Disziplin, die ein Teilgebiet der KI darstellt. Beim Maschinellen Lernen handelt es sich um eine Klasse von Algorithmen und Verfahren, die Daten interpretieren und aus diesen lernen. Die erlernten Informationen werden dann verwendet, um fundierte und genaue Entscheidungen zu treffen. Maschinelles Lernen lässt sich generell in drei Kategorien einteilen: **überwachtes Lernen**, **unüberwachtes Lernen** und **bestärkendes Lernen**. Beim überwachten Lernen lernt das Modell eine Funktion aus gegebenen Beispielen von Ein- und Ausgaben. Dieser Lernvorgang wird überwacht genannt, da für jede Eingabe die richtige Ausgabe bekannt ist und man das Modell bei falschen Vorhersagen korrigieren kann. Mithilfe des überwachten Lernens lassen sich Vorhersagen zu unbekannten oder künftigen Daten treffen – dies wird prädiktive Modellierung genannt.

Beim unüberwachten Lernen erzeugt der Algorithmus für eine gegebene Menge von Eingaben ein Modell, das die Eingaben beschreibt und Vorhersagen ermöglicht. Bestärkendes Lernen stellt eine Methode des Maschinellen Lernens dar, in der ein Algorithmus durch Belohnung und Bestrafung eine Taktik erlernt, selbstständig innerhalb des gegebenen Kontextes zu agieren. Jede Lösung wird dabei typischerweise mit einer Punktzahl bewertet. Belohnung wird durch die Erhöhung der Punktzahl und Bestrafung durch die Verringerung angegeben. Der Algorithmus versucht durch die Anpassung seiner Taktik die Punktzahl zu steigern. Ein detaillierter Einblick in das Thema Maschinelles Lernen findet sich in dem vom VDMA herausgegebenen „Quick Guide Machine Learning“ [1].

Ein weiterer Terminus, der in den letzten Jahren im Zusammenhang mit KI verstärkt verwendet wurde, ist das sogenannte **Deep Learning** (mehrschichtiges oder tiefes Lernen). Deep Learning (DL) ist eine spezielle Methode der Informationsverarbeitung und ein Teilbereich des Maschinellen Lernens. Hierbei werden **Künstliche Neuronale Netze** eingesetzt, um die Zusammenhänge in extrem großen Datenmengen zu erlernen. Die Lernmethoden orientieren sich an der Funktionsweise des menschlichen Gehirns, das im Grunde aus miteinander verbundenen Neuronen besteht. Diese einzelnen Neuronen führen einfache, elementare Operationen aus. Ein Netz aus Tausenden oder Millionen Neuronen kann sehr komplexe Zusammenhänge abbilden. Abbildung 4 stellt die Einordnung und den groben zeitlichen Entwicklungsrahmen für KI, ML und DL dar.




Abbildung 4: Einordnung von KI, ML und DL

Zu Beginn einer näheren Beschäftigung mit Künstlicher Intelligenz muss eine weitere, wesentliche Unterscheidung getroffen werden, die in erster Linie begrifflicher Natur ist. Oft wird zwar die Bezeichnung **Künstliche Intelligenz** verwendet, aber im Grunde genommen sind damit zwei sehr unterschiedliche Teilbereiche gemeint. Künstliche Intelligenz kann demnach in starke und schwache Ausprägungen unterteilt werden.

Schwache Künstliche Intelligenz (engl.: **weak Artificial Intelligence (AI)** oder **narrow AI**) bezieht sich auf Systeme, die sich auf die Lösung konkreter Problemstellungen fokussieren. Die Problemlösung erfolgt hierbei auf Basis von Methoden der Mathematik und Informatik, die für die jeweiligen Anforderungen entwickelt und optimiert werden. Das resultierende System kann dazu in der Lage sein,

sich selbst zu optimieren. Schwache Künstliche Intelligenz wird bereits in vielen Bereichen eingesetzt. Einige Beispiele hierfür sind Bilderkennung, Spracherkennung und automatisierte Übersetzungen.

Das Ziel einer **starken Künstlichen Intelligenz** (engl.: **strong AI** oder **general AI**) hingegen ist es, die gleichen intellektuellen Fertigkeiten wie ein Mensch zu erlangen oder diese zu übertreffen. In Zukunft – so die Vision der Forschung – werden damit alle Aufgaben erfüllt werden können, die heute nur ein Mensch bewältigen kann. Bis jetzt ist es jedoch noch nicht gelungen, eine starke Künstliche Intelligenz zu entwickeln. Zudem ist die Frage, ob die Entwicklung einer solchen Intelligenz überhaupt möglich ist, nicht abschließend geklärt.

Fähigkeiten und industrielle Anwendung von Künstlicher Intelligenz

Systeme auf der Basis Künstlicher Intelligenz (KI) lassen sich beispielsweise nach ihren Fähigkeiten einteilen. Diese Fähigkeiten können unterschiedlich detailliert beschrieben werden. Dadurch, dass das Feld der KI kontinuierlich wächst, ergeben sich stetig neue Fähigkeiten und Anwendungsmöglichkeiten. Bei einer zu detaillierten Einteilung besteht daher die Gefahr, neue Entwicklungen aus dem Auge zu verlieren. Zudem würde dadurch die Verständlichkeit und Übersichtlichkeit erschwert werden. Der vorliegende Leitfaden fokussiert daher die grundlegenden Fähigkeiten eines KI-Systems – **Beurteilen**, **Schlussfolgern** und **Reagieren** – und zeigt Anwendungsbeispiele für Unternehmen auf.

Eine übliche Darstellung von KI-Systemen ist in Abbildung 5 zu sehen. Ähnlich wie der Mensch nimmt ein Softwareagent, dem ein KI-System zugrunde liegt, seine Umwelt wahr und schließt hieraus auf geeignete Aktionen, um eine spezifische Aufgabe zu erfüllen. KI-Methoden können hierbei eingesetzt werden, um Beobachtungen zu beurteilen, Schlüsse zu ziehen oder direkt Aktionen abzuleiten und auszuführen. In der praktischen Umsetzung von KI-Systemen

werden – abhängig von den technischen Möglichkeiten und dem angestrebten Grad der Autonomie des Systems – oftmals nur einzelne dieser Fähigkeiten mithilfe von Algorithmen des Maschinellen Lernens umgesetzt. Die verbleibenden Funktionen können mithilfe von vordefinierten Regeln ausgeführt werden. So kann beispielsweise die durch entsprechende Bilderverarbeitung durchgeführte Klassifikation eines Bauteils als Ausschuss ein direktes Auswerfen des fehlerhaften Bauteils einleiten. Doch in den meisten Anwendungsfällen bleibt noch der Mensch in der Verantwortung, um aus den Beurteilungen und Schlüssen der KI-Systeme Handlungsentscheidungen abzuleiten und entsprechend zu reagieren.

Auf der folgenden Seite werden die drei grundlegenden Fähigkeiten mit beispielhaften Anwendungen abgebildet und entsprechenden Unternehmensbereichen zugeordnet (siehe Abbildung 6).




Abbildung 5: An Stuart Russel [2] und die High-Level Expert Group der Europäischen Kommission [3] angelehnte Darstellung eines KI-Systems und seiner Fähigkeiten (ERP: Enterprise-Resource-Planning, CRM: Customer-Relationship-Management)

	Marketing, Vertrieb & Service	Produkt- entwicklung	Supply Chain Management & Einkauf	Produktions- steuerung & Intralogistik	Produktions- prozess	Qualitäts- sicherung	Bereichs- übergreifend
Beurteilen	Einlesen handschriftl. Dokumente			Autom. Wareneingangs- kontrolle	Optische Sicherheitssysteme Anomalien- erkennung Softsensoren	Automatische Qualitäts- sicherung	Klassifikation von Berichten
Schlussfolgern	Preisindikation für Neuaufträge	Unterstützung der Produkt- konfiguration	Absatz- vorhersage	Optimierung der Produktions- steuerung Lager- optimierung	Predictive Maintenance Predictive Quality Parameter- optimierung		Intelligente Ansprech- partnersuche
Reagieren	Chatbots			Fahrerlose Transportsysteme (FTS)	Autonome Robotersysteme Intelligente Regelungs- verfahren		Robotic Process Automation (RPA)
Relevanz:		gering	mittel	hoch			

Abbildung 6: Übersicht beispielhafter KI-Anwendungen und ihrer primären Unternehmensbereiche; Abschätzung der Relevanz der Fähigkeiten in spezifischen Unternehmensbereichen auf Basis bestehender Anwendungsfälle

Beurteilen

Eine wesentliche Fähigkeit von KI-Systemen besteht darin, auf Basis von Daten Rückschlüsse auf den Zustand der Umwelt ziehen zu können (siehe Abbildung 7). Dies kann genutzt werden, um den Menschen bei repetitiven Arbeiten zu unterstützen. So lassen sich durch KI-Methoden viele Krankheitsfälle in Röntgenbildern bereits zuverlässiger erkennen als durch das menschliche Auge des ärztlichen Personals. Doch leisten Ärzt*innen mehr, als Anomalien auf Röntgenbildern zu erkennen. Es bleibt die Aufgabe des Menschen, aus den Informationen den Krankheitszustand der Patient*innen und notwendige Handlungen abzuleiten. Auch im produzierenden Gewerbe können die Mitarbeitenden durch diese KI-Methoden unterstützt werden.

Beispielhafte Anwendungen

- Einlesen handschriftlicher Dokumente: Dokumente wie beispielsweise neue Aufträge werden oftmals noch handschriftlich ausgefüllt. Durch automatisches Einlesen dieser Dokumente kann das Personal bei der Auftragsannahme unterstützt werden.
- Autom. Wareneingangskontrolle / Autom. Qualitätssicherung: Durch Methoden der Bilderkennung ist es möglich, automatische Sichtprüfungen von Bauteilen auf Fehlerhaftigkeit in vor- und nachgelagerten Prozessen der Produktion durchzuführen.
- Anomalieerkennung: Bei der Vielzahl an Echtzeitdaten in der Produktion ist es für den Menschen oftmals schwer zu erkennen, ob sich Werte außerhalb der Norm bewegen. Maschinelle Lernverfahren können helfen, zu beurteilen, ob Werte sich kritischen Grenzen nähern.
- Softsensoren / Virtual Sensors: Wichtige Messgrößen können teilweise nicht oder nur mit hohem finanziellen Aufwand über entsprechende Sensorik aufgenommen werden. Durch Korrelationen mit anderen Messgrößen können diese aber dennoch über entsprechende KI-Methoden abgeleitet werden.




Abbildung 7: Auf Basis von Daten erkennen, was in der Umwelt geschieht (Beurteilen), zum Beispiel durch die semantische Interpretation von Bildern oder die Anomalieerkennung in Tabellen

Anwendungsfall 1

Intelligenter NIR-Sensor zur Identifikation transparenter Folien

Kiefel GmbH

Ausgangssituation/Zielsetzung

Fehlbeladungen bei der Herstellung von Produkten aus transparenten Folien können zu umfangreichen Produktionsausfällen führen. Eine integrierte Qualitätskontrolle der Folien soll eine stabile Produktion gewährleisten.

Ergebnis

Mit einem inline integrierten NIR-Sensor und der Support-Vector-Network-Auswertung kann eine 100%ige Qualitätskontrolle des Materials während der Produktion, beispielsweise von medizinischen Beuteln, ermöglicht werden.

Umsetzung

Um unterschiedliche Folienparameter wie z. B. Materialtyp, Dicke oder Chargenunterschiede identifizieren zu können, wurde ein mehrstufiges System aus verschiedenen trainierten Support Vector Machines (SVM) aufgebaut. Grundlage für das Training waren Messdaten eines Standard-Nahinfrarotspektroskopie-sensors (NIR) für einige hundert üblicherweise verwendeter Folien.




Abbildung 8: NIR-Sensor mit KI-Auswertung (Kiefel GmbH)

Anwendungsfall 2

Qualitätsprüfung in der Lebensmittelindustrie

MVTec Software GmbH

Ausgangssituation/Zielsetzung

Aufgrund der variablen Morphologie von handgefertigten Erzeugnissen sind regelbasierte Ansätze der Bildverarbeitung nicht zur automatisierten Qualitätsprüfung von Backwaren wie beispielsweise Blätterteigstangen nutzbar.

Umsetzung

69 Backwaren laufen pro Blech unter einer Zeilenkamera hindurch. Mit der Bildverarbeitungsbibliothek MVTec HALCON wird zunächst eine Deep-Learning-basierte Object Detection durchgeführt und die detektierten Objekte werden vermessen. Im Anschluss werden die Backwaren von einem Deep Neural Network nach Bräunungsgrad und Gleichförmigkeit der Zutaten klassifiziert.

Ergebnis

Deep Learning hat den Vorteil, dass die erfahrungsbasierte Entscheidung, ob eine Backware zu stark oder zu schwach gebräunt ist, durch die vorgelagerte Annotation auf die automatisierte Entscheidungsfindung übertragen werden kann. Dadurch gelingt auch die Qualitätsprüfung von Objekten mit variabler Größe, Form, Struktur und variablem Hintergrund.



Abbildung 9: Backwarenprüfung mit MVTec HALCON und Deep Learning: Die Höhe der Bounding Box der detektierten Objekte dient als Maß für die Länge. Rot: Klassifiziert als zu starker Bräunungsgrad. Gelb: Klassifiziert als mit zu wenig Käse versehen (MVTec Software GmbH)

Anwendungsfall 3

Teilerkennung und Qualitätssicherung mittels Image Recognition und Deep Learning am Beispiel von Schraubenmuttern

The MathWorks GmbH

Ausgangssituation/Zielsetzung

Die visuelle Qualitätssicherung von losen und in großen Stückzahlen produzierten Teilen wie Schraubenmuttern ist mit herkömmlichen technischen Mitteln nur schwer umsetzbar. KI soll dabei helfen, die Teile in verschiedenster Ausrichtung zu detektieren und auf Qualitätsmerkmale hin zu überprüfen.

Ergebnis

Durch den Einsatz von KI-Methoden kann die Sichtprüfung durch eine automatisierte Inspektion ersetzt werden. Dadurch ist es möglich, visuelle Qualitätssicherung flexibel auf unterschiedliche Produkte umzustellen und eine große Anzahl an Teilen in kurzer Zeit zu überprüfen.

Umsetzung

Die Muttern wurden mit einer Digitalkamera erfasst, im Tool MATLAB eingelesen und mittels Computer Vision detektiert. Ein Deep-Learning-Algorithmus wurde dann mithilfe einer großen Anzahl von intakten und beschädigten Muttern darauf trainiert, zerkratzte von unbeschädigten Teilen zu unterscheiden.




Abbildung 10: Automatisierter visueller Qualitätscheck der Schraubenmuttern mit einem auf einem Embedded Device implementierten Neuronalen Netz (The MathWorks GmbH)

Anwendungsfall 4

Physikalisch inspirierte Softsensoren

Siemens AG

Ausgangssituation/Zielsetzung

In großen elektrischen Maschinen sind kaum Sensordaten zur Innentemperatur vorhanden. Basierend auf dem im Entwicklungsprozess entstandenen Wissen aus Simulationen sollen Rotor-Temperaturen in Form von virtuellen Sensordaten für die Temperaturregelung zur Verfügung gestellt werden.

Ergebnis

Durch die genaue Kenntnis nicht direkt messbarer Betriebszustände können sowohl ein zu konservativer Betrieb als auch Stillstandszeiten durch hitzebedingte Schädigungen vermieden werden, welche Kosten von bis zu 200 000 €/h bei großen elektrischen Motoren in der Öl- und Gas-Industrie verursachen können.

Umsetzung

Auf Basis von Simulationen mit unterschiedlichen thermischen Lasten wurden mittels Dimensionsreduktion und speziellen physikalisch inspirierten Neuronalen Netzen effiziente thermische Ersatzmodelle realisiert. Diese können betriebsynchron Temperaturen im gesamten Motor schätzen und eine drohende Überhitzung frühzeitig erkennen.




Abbildung 11: Eine 1000-fach beschleunigte Simulation mittels physikalisch inspirierter Neuronaler Netze erlaubt es, räumliche Temperaturverteilungen in elektrischen Maschinen parallel zum Betrieb kontinuierlich zu bestimmen (Siemens AG)

Schlussfolgern

Neben der Beurteilung der Umwelt können datenbasierte Methoden auch dazu genutzt werden, neue Erkenntnisse zu gewinnen und dem Menschen zusätzliche Informationen zur Entscheidungsunterstützung zu liefern (siehe Abbildung 12). So können Daten aus der Vergangenheit ausgewertet werden, um Prognosen für zukünftige Wertverläufe zu erstellen oder Lösungsvorschläge zu generieren. Auf Basis der Schlussfolgerungen wäre es oftmals möglich, direkt Aktionen abzuleiten. Im industriellen Einsatz steht allerdings zumeist noch der Mensch vor der eigentlichen Entscheidung, welche Aktionen durchgeführt werden sollen. Hierdurch können KI-Systeme bei der Unterstützung des Menschen einen Nutzen bringen, ohne die Risiken eines vollautonomen Systems in sich zu bergen.

Beispielhafte Anwendungen

- Absatzvorhersage: Die Vorhersage von Absatzzahlen kann dazu genutzt werden, Einkäufe zielgerichteter an zukünftige Nachfragewerte anzupassen.
- Vorausschauende Wartung / Predictive Maintenance: Auf Basis vergangener Verläufe von Sensorwerten und korrelierender Maschinenausfälle ist es möglich, zukünftige Ausfälle vorherzusagen und somit die Wartung zu optimieren.
- Predictive Quality: Durch die Erkennung von Korrelationen zwischen Sensorwerten und Ergebnissen aus der Qualitätssicherung können mögliche Produktfehler bereits während des Prozesses erkannt werden. Neben dem Zustand des Produkts werden hierbei zumeist auch Handlungsempfehlungen zu Betriebswerten der Maschine abgeleitet.
- Parameteroptimierung: Datenbasierte Methoden können zum Einsatz kommen, um auf Basis vergangener Konfigurationen und Leistungsindikatoren wie der Taktzeit Handlungsempfehlungen für die Maschinenbedienerperson abzuleiten.



Abbildung 12: Auf Basis von Daten auf relevante Erkenntnisse schließen (Schlussfolgern)

Anwendungsfall 5

Intelligente Suche nach Expert*innen

iteratec GmbH

Ausgangssituation/Zielsetzung

Die unternehmensinterne Suche nach Expert*innen zu einem bestimmten Thema soll deutlich schneller und einfacher sein.

Mithilfe einer Feedback-Funktion lernt das System die Gewichtung zwischen den unterschiedlichen Datenquellen aus den Interaktionen der Anwender*innen.


Ergebnis

Umsetzung

Die Suche wertet Datenquellen wie eine Skilldatenbank, Chats oder Projektbeschreibungen mit Methoden des Natural Language Processing aus und empfiehlt Expert*innen. Zusätzlich werden anhand eines Abgleichs mit Schlagwörtern von der Internetplattform **Stack Overflow** und semantischer Ähnlichkeiten verwandte Themen vorgeschlagen.

Ansprechpartner*innen zu speziellen Themen lassen sich schneller und einfacher finden. Dadurch können Mails oder Anfragen „An alle“ vermieden werden. Dank der flexiblen Architektur können neue Informationsquellen leicht in das System integriert werden.

Abbildung 13: Screenshot von der Plattform, in der Expert*innen mit Stichworten gefunden und über Contact Group angeschrieben werden können (iteratec GmbH)



Anwendungsfall 6

Fehlervorhersage unter Einbeziehung von Expert*innenwissen am Beispiel additiv gefertigter Werkstücke

XITASO GmbH

Ausgangssituation/Zielsetzung

Bei additiv gefertigten Bauteilen sollen im FDM-Prozess (Fused Deposition Modeling) auftretende Fehler, wie Verwindungen oder fehlerhaft platziertes Material, auf Basis von Daten zu Prozess- und Umgebungsparametern, wie Extrusionstemperatur, Materiallieferant und Umgebungstemperatur, vorhergesagt werden. Aufgrund der geringen Datenmenge konnte allein mit Methoden des Maschinellen Lernens keine zuverlässige Fehlervorhersage getroffen werden.

Umsetzung

Als Ausgangspunkte dienten ein mit vorhandenen Daten trainiertes Neuronales Netz und das in Entscheidungsbäumen abgebildete Expert*innenwissen. Mittels Active Learning wurde das in den Entscheidungsbäumen hinterlegte Wissen anschließend in das Neuronale Netz übertragen.

Ergebnis

Durch die Integration von Expert*innenwissen konnte die Vorhersagegenauigkeit trotz der geringen Menge an Trainingsdaten enorm verbessert werden. Die Vorhersagegenauigkeit stieg im untersuchten Beispiel durch Hinzunahme des Expert*innenwissens von 9 % auf 95 %.




Abbildung 14: Unerwünschte Fadenbildung (XITASO GmbH)

Anwendungsfall 7

Vorausschauende Wartung (Predictive Maintenance) in der Folienherstellung

The MathWorks GmbH

Ausgangssituation/Zielsetzung

Bei Anlagen zur Folienherstellung zeichnen die Industriesteuerungen Daten von bis zu 400 unterschiedlichen Sensoren auf. Diese Daten sollen verwendet werden, um Probleme frühzeitig zu erkennen und Produktionsausfälle zu vermeiden.

fassen. Das auf der Grundlage dieser Technik entwickelte Modell sagt insbesondere potenzielle Folienrisse vorher. Der Algorithmus wurde in die bestehende IT-Infrastruktur integriert und zeigt über eine Bedienoberfläche an, ob ein Eingriff notwendig ist.

Umsetzung

Aus den kontinuierlich aufgezeichneten und aufbereiteten Sensordaten erkennt ein Bagged-Decision-Trees-Modell die Produktqualität der Kunststoffolie. Das Bagging ist eine Ensemble-Methode und wird im Bereich des Maschinellen Lernens eingesetzt, um mehrere einzelne Modelle (hier Decision Trees bzw. Entscheidungsbäume) zu einem Modell zusammenzu-

Ergebnis

Durch den Einsatz von KI-Methoden für die vorausschauende Wartung können signifikante Einsparungen durch Vermeidung von Maschinenstillständen erzielt werden. Die Applikation wurde in das bestehende IT-System integriert und läuft 24/7, um das Bedienpersonal bei der Sicherstellung der Produktionsqualität zu unterstützen.




Abbildung 15: Eine MATLAB-basierte Benutzeroberfläche informiert Bediener*innen über potenzielle Störungen, die an der Anlage zu erwarten sind (The MathWorks GmbH)

Anwendungsfall 8

Vorausschauende Wartung (Predictive Maintenance) mit Condition Monitoring für Frässpindeln

Siemens AG

Ausgangssituation/Zielsetzung

Ein KI-Algorithmus soll Anomalien in den Rohdaten erkennen und eine automatisierte Mail an die Bediener*innen auslösen, damit diese die Spindel rechtzeitig wechseln.

Ergebnis

Durch den rechtzeitigen Spindeltausch wird ein ungeplanter Stillstand der Fräsmaschine und der nachfolgenden Systeme verhindert.

Umsetzung

Zwei analoge Signale (Strom und Drehzahl) werden mit einem Edge-Gerät von einem Regler der Spindel abgegriffen und vorverarbeitet. Anschließend werden die Rohdaten mit einem Algorithmus verarbeitet. Wenn eine Anomalie auftritt, soll die Spindel getauscht werden.



Abbildung 16: Spindel im Fräsvorgang
(Siemens AG)

Reagieren

Durch direkte Interaktion mit der Umwelt können KI-Systeme lernen, welchen Einfluss ihre durchgeführten Aktionen haben und welche Aktionen in Zukunft ausgeführt werden müssen, um ein bestimmtes Ziel zu erreichen (siehe Abbildung 17). So erlernte der Algorithmus AlphaGo als ein Computerprogramm mit den Techniken des Maschinellen Lernens, alleine durch die Ausführung von Spielzügen und aus dem Feedback gewonnener bzw. verlorener Spiele das Brettspiel Go zu meistern und besiegte 2016 sogar den Weltmeister Lee Sedol. Auf ähnliche Weise werden Methoden für den Finanzmarkt entwickelt, um Aktienkäufe bzw. -verkäufe zu optimieren. Die Fähigkeit eines KI-Systems, direkt mit der Umwelt zu interagieren und aus den Erfahrungen zu lernen, kann auch in verschiedenen Unternehmensbereichen genutzt werden.

Beispielhafte Anwendungen

- **Chatbots:** Chatbots lernen die natürliche Sprache menschlicher Anfragen zu interpretieren und auf diese Weise Service-Leistungen zu automatisieren. Durch neue menschliche Anfragen und Antworten von Service-Mitarbeiter*innen können diese Systeme weiterlernen und ihre Präzision bei der Beantwortung von Fragen verbessern.
- **Fahrerlose Transportsysteme (FTS):** Ähnliche Methoden wie beim autonomen Fahren können in der Intralogistik eingesetzt werden, um FTS selbstständig durch Produktionshallen und Lager fahren und Bauteile transportieren zu lassen.
- **Autonome Robotersysteme:** Durch entsprechende Kamerasysteme können Roboter den Zustand ihrer Umwelt erkennen (z. B. unterschiedliche Bauteilpositionen) und so auch unter variierenden Umgebungsbedingungen ihre Aufgabe durchführen.
- **Robotic Process Automation (RPA):** Bei RPA werden die oftmals repetitiven Arbeiten am Computer durch entsprechende Algorithmen analysiert und automatisiert. Selbstlernende RPA-Systeme sind darüber hinaus in der Lage, weiterzulernen und sich selbst zu optimieren.




Abbildung 17: Auf Basis von Daten direkten Einfluss auf die Umwelt ausüben (Reagieren)

Anwendungsfall 10

KI-basierte Objekterkennung und -aufnahme durch einen Pick-&-Place-Roboter

The MathWorks GmbH

Ausgangssituation/Zielsetzung

Das Erkennen und Aufnehmen von Objekten durch Pick-&-Place-Roboter muss bei herkömmlicher Anwendung durch einen Operator trainiert werden. In den Trainingsdaten nicht enthaltene Objekte, wie etwa neue Produkte, müssen dem System zeitaufwändig angelernt werden. KI-Methoden sollen den Roboter dazu befähigen, bisher unbekannte Objekte zu detektieren und aufzunehmen.

Umsetzung

Der zusätzlich mit einer Kamera ausgerüstete Roboterarm wird im Tool MATLAB mittels Bilderkennung und Deep Learning auf eine Anzahl unterschiedlicher Objekte trainiert, sodass er diese selbstständig erkennen und aufnehmen kann. Neu hinzugefügte ähnliche Objekte können mit geringem zusätzlichen Trainingsaufwand ebenfalls erkannt und aufgenommen werden.

Ergebnis

KI-Methoden können genutzt werden, um das Erkennen und Aufnehmen von neu hinzugekommenen Objekten mittels Pick-&-Place-Roboter zu ermöglichen.



Abbildung 19: Ein Roboterarm wird mithilfe von KI-Methoden eingesetzt, um flexibel unterschiedliche Objekte in einem Lager zu detektieren und aufzugreifen (The MathWorks GmbH)

Anwendungsfall 11

Erkennen optimaler Greifpunkte an unbekannten Objekten

Siemens AG

Ausgangssituation/Zielsetzung

Das Greifen von Teilen durch Roboter erfordert bislang, dass die Objekte bekannt sind und in fester Position und Orientierung liegen. Die Greifpunkte werden in diesem Fall für jedes Objekt explizit programmiert. Durch den Einsatz von KI soll es ermöglicht werden, auch unbekannte Objekte zu greifen.

Objekte generalisiert. Für die effiziente Ausführung wurde der Algorithmus an der speicherprogrammierbaren Steuerung (SPS) auf einem industriellen KI-Modul integriert, welches die Greifpunkte direkt zur Steuerung des Roboterarms weiterleitet.

Ergebnis

Es wurde eine Basis für viele Anwendungsfälle in der flexiblen Fertigung geschaffen, die durch eine automatisierte Erzeugung und Bewertung potenzieller Greifpunktpaare eine wirtschaftliche Produktion in Losgröße 1 im Kontext von Industrie 4.0 ermöglicht.

Umsetzung

Anhand eines Datensatzes mit diversen Objekten wurde ein Künstliches Neuronales Netz trainiert, das optimale Greifpunkte bestimmt und für unbekannte



Abbildung 20: Die Neural Processing Unit in der Steuerung generiert Greifpunktpaare an senkrechten Flanken des Objektes und bewertet diese mithilfe eines Künstlichen Neuronales Netzes (Siemens AG)

KI-Potenziale im eigenen Unternehmen identifizieren

Ohne Vorerfahrung im Bereich Künstliche Intelligenz (KI) ist es schwer abschätzbar, wo im Unternehmen das größte Potenzial für den Einsatz von KI besteht und mit welchem Aufwand ein Umsetzungsprojekt verbunden sein wird. Das richtige Vorgehen zur Identifikation geeigneter Anwendungsfälle hängt zudem stark von den Rahmenbedingungen des Unternehmens ab (betrachtete Unternehmensbereiche, zeitlicher Rahmen usw.). Die wesentlichen Phasen und ihre KI-spezifischen Charakteristika lassen sich allerdings verallgemeinern. In der Projektgruppe „Künstliche Intelligenz“ des VDMA wurden die Erfahrungen mehrerer Unternehmen gesammelt und für den Leitfaden zusammengefasst (siehe Abbildung 21).

Vorbereitung

Vor einem Workshop stellt sich zunächst die Frage, wer daran teilnehmen sollte, um Ideen zur Anwendung von KI generieren und bewerten zu können. Neben Geschäftsführer*innen und Entscheidungsträger*innen sind hier auch die Mitarbeitenden wichtig, welche einzelne Prozesse und Bereiche im Unternehmen am besten kennen (Domänen-Expert*innen), sowie die möglichen Nutzenden von KI-Anwendungen. Auch können Lieferanten oder Kunden in den

Prozess mit einbezogen werden, da sich ein KI-Projekt für mehrere Partner entlang der Wertschöpfungskette bezahlt machen kann. Um Ideen für mögliche KI-Anwendungsfälle im Unternehmen finden zu können, ist zudem ein gewisses Grundverständnis zu KI wichtig. Die vorherigen Kapitel des Leitfadens dienen hier als Orientierungshilfe, um Basiswissen zu den Möglichkeiten von KI zu vermitteln. Weiterführend können auch externe Expert*innen oder der VDMA-Quick-Guide „Machine Learning im Maschinen- und Anlagenbau“ [1] herangezogen werden.

Ideenfindung

In der Phase der Ideenfindung soll zunächst eine Vielzahl an Vorschlägen für mögliche KI-Anwendungsfälle gesammelt werden. Wie in jedem Kreativworkshop ist es auch hier wichtig, eine gewisse Offenheit gegenüber verschiedenen Ideen zu wahren und unter den Teilnehmenden eine disziplinierte und respektvolle Arbeitsatmosphäre zu fördern. Neben dem herkömmlichen Brainstorming können auch andere Methoden in Betracht gezogen werden. Bei der Kärtchen-Technik schreiben bspw. alle ihre Ideen zunächst auf eigene Kärtchen, welche gesammelt und anschließend in der Gruppe diskutiert werden.




Abbildung 21: Vier Phasen zur Identifikation geeigneter KI-Anwendungsfälle im eigenen Unternehmen

Nutzen Was ist der Nutzen des Anwendungsfalls? Warum soll der Anwendungsfall realisiert werden?			
Vorhersage - Was soll Vorhergesagt werden? - Welche Entscheidung soll getroffen werden? - ...	Verifikation - Wie kann die Vorhersage überprüft werden? - Wie kann die Entscheidung abgesichert werden? - ...	Aktion - Welche Aktion soll durch Vorhersage angestoßen werden? - Wie soll die Aktion angestoßen werden? - ...	Wirksamkeit - Wie kann die Wirksamkeit der Aktion geprüft werden? - Wie kann der Nutzen geprüft werden? - ...
Daten - Welche Daten werden benötigt? - Wie wird auf die Daten zugegriffen? - Wer muss eingebunden werden? - Müssen zusätzliche Daten erfasst werden? - ...	Training - Wie viele Daten sind vorhanden? - In welcher Qualität liegen die Daten vor? - ...		Optimierung - Wie kann das System kontinuierlich dazulernen? - Welche Daten werden dazu benötigt? - ...

Abbildung 22: Beispielhafte Vorlage zur Ausarbeitung eines Anwendungsfalls (iteratec GmbH)

Die nähere Auseinandersetzung mit den einzelnen Ideen ist mit einem gewissen Aufwand verbunden. Die Vorschläge müssen gefiltert werden und es sollte, beispielsweise durch Punktevergabe aller Teilnehmenden mit Klebepunkten, hier bereits eine Priorisierung erfolgen.

Ausarbeitung der Anwendungsfälle

Bevor die einzelnen potenziellen Anwendungsfälle bewertet werden können, ist deren nähere Ausarbeitung notwendig. Zunächst sollte der Fokus darauf gelegt werden, den Nutzen des Projekts zu quantifizieren und zu beurteilen. Ein offensichtlicher Aspekt ist hier die Reduktion von Ausschuss oder Maschinenausfallzeiten. Daraus sollten sich die Mindestanforderungen zur erfolgreichen Demonstration eines Proof of Concept ableiten lassen. Doch auch weiche Faktoren wie die Humanisierung der Arbeit oder der Aufbau von Kompetenz können Kriterien für die Entscheidungsfindung darstellen. So ist es möglich, bereits während des Projekts wertvolle

Erkenntnisse zu den betrachteten Prozessen und Handlungsempfehlungen für die Datenaufnahme abzuleiten.

Wesentliche Kriterien zur Abschätzung der Machbarkeit und des Aufwands in der Umsetzung von KI-Projekten sind die Datenverfügbarkeit, die Datenmenge und die Datenqualität. Eine genauere Aussage zur notwendigen Datenmenge und Datenqualität können nur Expert*innen machen und im Rahmen eines Projekts validieren. Um als Unternehmen bereits erste eigene Abschätzungen vornehmen zu können, wird im folgenden Kapitel ein Überblick über die wesentlichen Kriterien, die Daten erfüllen sollten, und ihre Auswirkungen auf Machbarkeit und Aufwand gegeben. Eine beispielhafte Vorlage zur Ausarbeitung von KI-Anwendungsfällen in Anlehnung an das **Business Model Canvas** ist in Abbildung 22 dargestellt. Das Business Model Canvas ist eine Planungsmethode zur Entwicklung neuer oder zur Dokumentation bestehender Geschäftsmodelle und Geschäftsideen. Es wird als Vorlage in vielen Innovationsprojekten verwendet und ist eine einfach zu verstehende Repräsentation von Geschäftsideen.




Abbildung 23: Ausschlusskriterien für KI-Projekte durch mangelnde Datenverfügbarkeit

Bewertung und Entscheidung

Sobald die einzelnen Anwendungsfälle ausgearbeitet worden sind, kann die Bewertung der Machbarkeit erfolgen. Dies stellt gerade beim ersten KI-Projekt eine große Herausforderung dar. Als Anhaltspunkt kann die Sammlung bestehender Anwendungsfälle in diesem Leitfaden dienen. Doch bereits während der Ausarbeitung der Anwendungsfälle können K.-o.-Kriterien wie zum Beispiel eine mangelnde Datenverfügbarkeit die Machbarkeit des Projekts ausschließen.

Ein wesentliches Kriterium für die weitere Entscheidungsfindung ist die bestehende Inhouse-Kompetenz des Unternehmens. Es sollte nicht nur die notwendige Kompetenz zur Umsetzung eines KI-Projekts betrachtet werden, sondern auch das interne Know-how, um ein initial aufgesetztes KI-System später betreiben zu können. Viele KI-Systeme müssen während des Betriebs gewartet werden, da sich die Prozesse (Produktvarianten, Maschinenverhalten, Kundenverhalten etc.) verändern und das KI-System aktuell gehalten werden muss (sog. **MLOps**).

Basierend auf der Inhouse-Kompetenz kann eine Make-or-Buy-Entscheidung getroffen werden. Bei der Entscheidungsfindung sollte die zunehmende Anzahl an Werkzeugen beachtet werden, welche einen niederschweligen Einstieg ermöglichen, indem sie einzelne Aspekte der Umsetzung automatisieren (z. B. AutoML Anbieter, Cloud Services). Gerade KI ist aber auch geprägt durch eine hohe Dynamik im Bereich der Forschung und enorme Innovationssprünge in Teildisziplinen wie Reinforcement Learning (RL), wo es um die Umsetzung autonomer Robotersysteme geht, oder Natural Language Processing (NLP), also der Verarbeitung natürlicher Sprache. In diesen Fällen kann auch die Wait-Entscheidung als dritte Alternative in Erwägung gezogen werden.

Datenverfügbarkeit, Datenmenge und Datenqualität

Daten bilden die Grundlage für alle KI-Systeme, welche mithilfe von maschinellen Lernverfahren die in den bestehenden Daten verborgenen Gesetzmäßigkeiten erkennen und diese nutzen, um aus später gewonnenen Daten Informationen ableiten zu können. Die Verfügbarkeit, Menge sowie die Qualität der Daten spielen daher eine entscheidende Rolle hinsichtlich der Machbarkeit und der Ergebnisse eines KI-Projekts.




Abbildung 24: Beispiel einer zu geringen Datenmenge und Datenqualität

Datenverfügbarkeit

Ohne Daten kein KI-System – ein Ausschlusskriterium für jedes KI-Projekt ist daher die mangelnde Verfügbarkeit und Anwendbarkeit bestehender Daten (siehe Abbildung 23). Auch wenn Daten bereits gesammelt wurden, können diese unzugänglich sein, da beispielsweise Kunden die Daten nicht freigeben möchten oder personenbezogene Daten nur unter Beachtung rechtlicher Vorgaben genutzt werden dürfen. Oftmals werden in einem KI-Projekt zudem Daten aus verschiedenen Quellen verwendet. Sollten die Daten nicht zuordenbar sein, können diese in einem KI-Projekt nicht angewandt werden und ein KI-Projekt wäre daher ebenfalls wegen mangelnder Datenverfügbarkeit nicht umsetzbar.

Datenmenge und Datenqualität

Die Menge und die Qualität der Daten sind die entscheidenden Erfolgsfaktoren für die Ergebnisse eines KI-Projekts und die Einsatzfähigkeit des angestrebten KI-Systems (siehe Abbildung 24). Daher sollten Domänen-Expert*innen des Unternehmens beurteilen, ob die verfügbaren Daten repräsentativ für den betrachteten Prozess sind und die Phänomene enthalten sind,

welche in einem späteren Betrieb des KI-Systems auftreten können. Beispielsweise kann ein KI-System zur Vorhersage der Bauteilqualität (Predictive Quality) nur Bauteilfehler aus Messdaten ableiten, welche bei ähnlichen Systemzuständen im betrachteten Datensatz enthalten sind. Auch wenn diese Voraussetzung erfüllt ist, können zu wenige Datenpunkte verfügbar sein, um die zugrunde liegenden Gesetzmäßigkeiten lernen zu können. Je komplexer die Zusammenhänge sind, desto mehr Datenpunkte sind in der Regel notwendig. Auch enthalten gesammelte Daten oftmals Fehler wie falsche oder fehlende Werte. Zudem sind menschliche Fehler bei der manuellen Aufnahme von Daten nicht immer vermeidbar und auch technische Fehler können bei der Datenaufnahme auftreten (z. B. defekte Sensoren). Solche Fehler können durch erhöhte Aufwände im Rahmen des KI-Projekts behandelt werden. Liegen allerdings zu viele Fehler vor, kann dies die Leistungsfähigkeit des KI-Systems stark beeinträchtigen.

Wann reichen Datenmenge und Datenqualität?

Eine aussagekräftige Beurteilung, ob die Datenmenge und die Datenqualität für das KI-Projekt und den Einsatz des KI-Systems ausreichend sind, lässt sich meist erst während der Umsetzung vornehmen. Dann wird erkennbar, ob sich aus den Daten verallgemeinerbare Gesetzmäßigkeiten für die Nutzung in einem späteren Betrieb ableiten lassen. Es existieren zudem zunehmend Ansätze, um mit geringen Datenmengen umgehen zu können. So kann im Bereich der Bilderkennung die Anzahl von Bilddaten durch Rotieren, Verschieben und Skalieren künstlich erhöht werden (sog. Data Augmentation). Auch können probabilistische Verfahren eingesetzt werden, wenn die Datenmenge nicht repräsentativ genug ist. Im Bereich der Forschung ist der Umgang mit geringen Datenmengen derzeit ein intensiv behandeltes Thema, wobei fortlaufend neue Methoden entwickelt werden, wie die Bilderkennung mit nur wenigen Bildaufnahmen (sog. One-Shot Learning bzw. Few-Shot Learning) oder der Transfer gelernter Zusammenhänge über mehrere Aufgabenstellungen hinweg (sog. Transfer Learning).

Rechtliche und ethische Grenzen

Neben den technischen Grenzen sollten auch rechtliche und ethische Rahmenbedingungen betrachtet werden. Wie im Rahmen der Datenverfügbarkeit erwähnt, können personenbezogene Daten (z. B. Fotos, Alter, Gewicht) bei KI-Anwendungen genutzt werden, wobei die Datenschutz-Grundverordnung (DSGVO) zu berücksichtigen ist und entsprechende Maßnahmen zur Erfüllung der rechtlichen Anforderungen durchgeführt werden müssen (z. B. Erstellung und Sammlung von Datenschutzerklärungen). Insbesondere sind diejenigen Daten kritisch zu betrachten, welche zu einer personenbezogenen Leistungsbewertung herangezogen werden können. Zudem werden durch KI-Anwendungen Entscheidungen getroffen oder vorbereitet, welche Einfluss auf Menschen haben können (z. B. bei Personalentscheidungen) und daher leicht nachvollziehbar sein sollten. Solche Anforderungen an die Transparenz der Entscheidungsfindung müssen bereits zu Projektbeginn definiert werden, da beispielsweise die Auswahl der verwendeten Methoden hiervon abhängen kann. Die „Assessment List for Trustworthy AI“ der High-Level Expert Group der Europäischen Kommission [4] bietet ein Werkzeug, um diese Prinzipien einer vertrauenswürdigen Künstlichen Intelligenz in der Praxis umzusetzen.

KI-Projekte erfolgreich umsetzen

Sobald ein Anwendungsfall identifiziert und ein Projektbudget freigegeben sowie ein Projektteam und eine geeignete Infrastruktur definiert sind, kann mit der Umsetzung der Anwendung auf Basis Künstlicher Intelligenz (KI) begonnen werden. Im Rahmen dieses Leitfadens wird dafür ein exemplarisches Vorgehensmodell vorgestellt, welches die elementaren Projektphasen vom Projektstart bis zum laufenden Betrieb des KI-Systems berücksichtigt.

Der folgend vorgestellte Ansatz (siehe Abbildung 25) orientiert sich am standardisierten Vorgehensmodell CRISP-DM (Cross Industry Standard Process for Data Mining), das 1996 durch branchenübergreifende Partner entwickelt wurde. Aus der bei KI-Projekten im Vergleich zu Data Mining begrenzten Datenmenge resultieren erweiterte Anforderungen hinsichtlich der

verwendeten Modelle. Um für KI-Anwendungen diesen Anforderungen beim Aufbau und der Wartung der Systeme gerecht zu werden, wurde das CRISP-DM-Modell für die Umsetzung von KI-Projekten adaptiert.

Zur erfolgreichen Umsetzung des KI-Projekts durchschreitet das Projektteam sequenziell verschiedene Projektphasen. Abhängig vom konkreten Projekt können die verschiedenen Phasen auch im Sinne einer agilen Entwicklung zusammengefasst, übersprungen und wiederholt werden. Eine einheitliche Phasenabfolge kann deshalb nur bedingt vorab festgelegt werden. Abbildung 25 illustriert acht verschiedene Projektphasen, welche im Regelfall vom Projektstart bis zum laufenden Betrieb durchschritten werden.


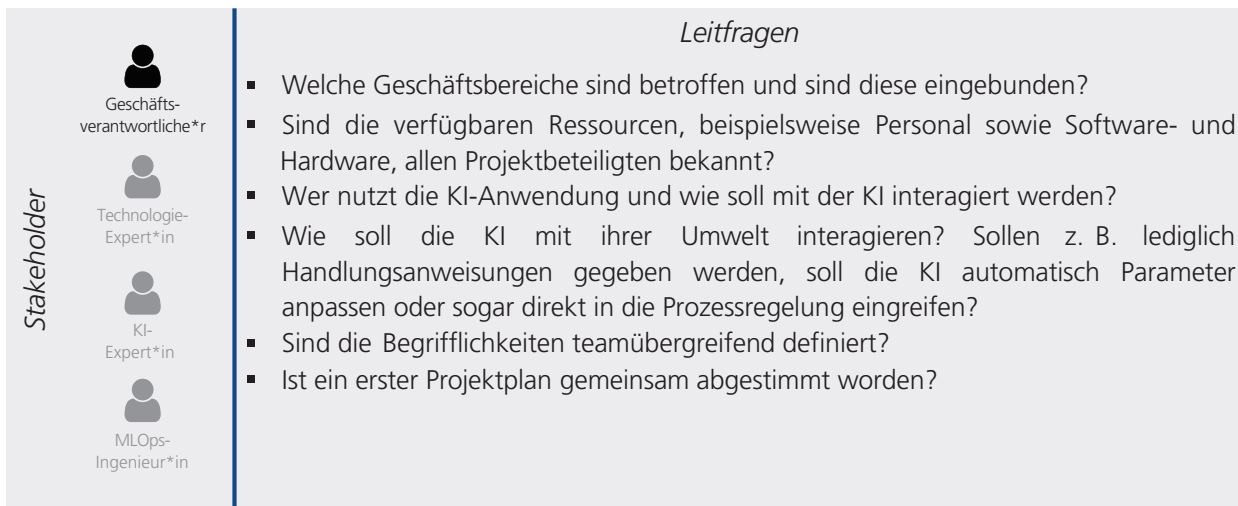


Abbildung 25: Vorgehensmodell zur Umsetzung des KI-Projekts

Phase 1



Üblicherweise werden die Phasen 4 (Modellierung) und 5 (Auswertung) iterativ durchschritten, bis die erforderliche Modellgüte erzielt werden kann.

Im Folgenden werden die einzelnen Projektphasen kurz erläutert. Zu jeder Projektphase werden die maßgeblich beteiligten Interessensvertreter*innen, nachfolgend als **Stakeholder** bezeichnet, benannt. Für jede Phase sind die hauptverantwortlichen und beteiligten Stakeholder gekennzeichnet. Diese setzen sich aus den Geschäftsverantwortlichen, den Technologie-Expert*innen, den KI-Expert*innen und den MLOps-Ingenieur*innen zusammen. In Anlehnung an **DevOps (Development Operations)**, die als Zusammenfassung von Prozessverbesserungsansätzen fungieren, werden **MLOps (Machine Learning Operations)** als eine entsprechende Ergänzung für die Lösungen im Bereich des Maschinellen Lernens verwendet. Wichtige Leitfragen zur jeweiligen Phase unterstützen bei der Durchführung und dienen als Orientierungshilfe. Diese Leitfragen sollten die Stakeholder fundiert durchdenken und beantworten können.

Phase 1 – Das Fundament: Das gemeinsame Geschäfts- und Projektverständnis

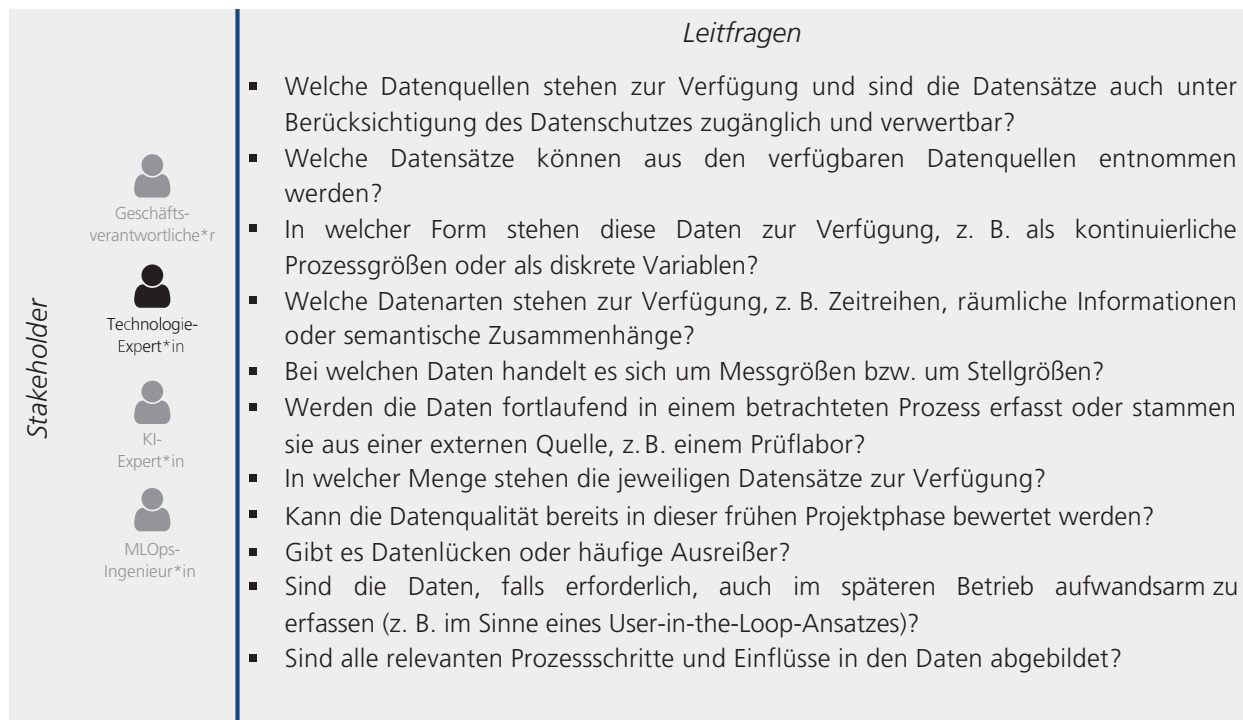
Wenn ein geeigneter Anwendungsfall identifiziert ist und die Freigabe für das Projekt vorliegt, sollte zunächst ein gemeinsames Geschäfts- und Projektverständnis aller Beteiligten geschaffen werden. Hierzu ist es notwendig, die im Business Model Canvas festgelegten Anforderungen, Ziele, Rahmenbedingungen und Erfolgskriterien in der ersten Projektphase beginnend zu konkretisieren, indem ein vorläufiger Projektplan gemeinsam erarbeitet wird.

Phase 2 – Die tragenden Säulen:**Das Technologie-, Prozess- und Datenverständnis**

Nachdem ein gemeinsames Geschäfts- und Projektverständnis aller Beteiligten im vorangegangenen Schritt geschaffen wurde, werden zunächst die bereits verfügbaren Daten, Datenstrukturen und Datenquellen gesammelt, gesichtet und aufbereitet. Maßgeblich beteiligt sind hierbei die Prozess- und Technologie-Expert*innen aufgrund ihres umfangreichen

Wissens und ihrer Erfahrungen mit dem zugrunde liegenden Prozess bzw. der zugrunde liegenden Technologie.

Ziel dieser zweiten Phase ist eine strukturierte Analyse zu den verfügbaren Daten und ihrer Herkunft, beispielsweise im Rahmen eines Workshops. Im Zuge dieser Analyse sollte untersucht werden, ob die Daten mit vertretbarem Aufwand auch in einer späteren Projektphase erneut gesammelt werden können, um das KI-System nachzutrainieren.

Phase 2

Phase 3

Stakeholder	Leitfragen
 Geschäfts- verantwortliche*r	▪ Sind die Rohdaten ausreichend gefiltert und aufbereitet, beispielsweise hinsichtlich Messrauschen, Ausreißern etc.?
 Technologie- Expert*in	▪ Gibt es ähnliche Problemstellungen, die bereits mit den zur Verfügung stehenden Daten gelöst wurden? Falls ja: Welche Merkmale wurden dabei verwendet?
 KI- Expert*in	▪ Welche physikalisch motivierten Merkmale können anhand der Daten identifiziert werden? ▪ Welche künstlichen Merkmale können aus den Daten erzeugt werden?
 MLOps- Ingenieur*in	▪ Kann bereits ein Zusammenhang zwischen den zu modellierenden Ausgangsgrößen der KI und den möglichen Merkmalen identifiziert werden? ▪ Wie stark schränkt die Wahl der Merkmale die Auswahl an möglichen Modellierungsansätzen bereits in dieser Phase ein?

Phase 3 – Der Rohbau:

Die Datenvorbereitung

Bevor mit der datenbasierten Modellierung in der folgenden Phase begonnen werden kann, müssen die zu verwendenden Rohdaten in Abhängigkeit des Modellierungsziels selektiert, bereinigt, gefiltert und formatiert werden. Diese Phase kann in vielen Projekten einen beachtlichen, wenn nicht gar den größten Zeitanteil einnehmen, weshalb sie in der Projektvorbereitung und Projektplanung besondere Berücksichtigung erfahren sollte.

Auf Basis der aufbereiteten Daten können, falls erforderlich, aussagekräftige Merkmale (**Features**) zur datenbasierten Modellierung identifiziert und konstruiert werden. Alternativ zur Ableitung von Merkmalen kann der anschließende Modellierungsschritt auch direkt mit den aufbereiteten Daten erfolgen. Die grundlegende Entscheidung, wie viel Technologie- und Prozesswissen in das sogenannte **Feature Engineering** (Generierung von Features aus den Rohdaten) mit einfließt, ist abhängig davon, wie viele Daten zur Verfügung stehen und wie stark das Technologie- und Prozessverständnis auf einzelne Merkmale heruntergebrochen werden kann bzw. wie viel Technologie- und Prozesswissen in das KI-System integriert werden soll. Diese Phase der Merkmalsidentifikation, -extraktion und -konstruktion stellt deshalb oft einen elementaren Baustein bei der Entwicklung einer KI-Anwendung dar.

Es gibt mehrere Möglichkeiten, sinnvolle Merkmale zu identifizieren, zu extrahieren und zu konstruieren:

- Die Merkmale können auf Basis von Technologie- und Prozessverständnis konstruiert werden, beispielsweise quantifizierbare Signaleigenschaften wie das Frequenzspektrum eines Sensorsignals oder abgeleitete Features aus Bildern. Die Konstruktion und Kombination verschiedener Merkmale kann unter Umständen auch künstliche und damit physikalisch wenig sinnhafte Merkmale erzeugen, die im späteren Modellierungsprozess dennoch zu einer hohen Modellgüte führen können.
Ein Beispiel für ein künstliches Feature ist die Autokorrelation eines Sensorsignals.
- Die Merkmale werden unter Zuhilfenahme automatischer und softwarebasierter Verfahren identifiziert und extrahiert (**Feature Learning**).
- Mit vortrainierten Modellen können verallgemeinerte, domänenspezifische Merkmale (z. B. für Bilddaten) genutzt werden.

Es muss jedoch beachtet werden, dass die Auswahl der aufbereiteten Daten und die daraus generierten Merkmale den folgenden Modellierungsschritt maßgeblich beeinflussen und die Auswahl möglicher Lernverfahren in der Modellierungsphase deutlich einschränken können. Je mehr Technologie- und Prozesswissen in einzelnen Merkmalen zusammengefasst werden kann oder je weniger Daten zur Abbildung der Zusammenhänge notwendig sind, desto verlässlicher ist die Modellierung auf Basis ausgewählter Merkmale, da das Training weniger komplex und die Ergebnisse einfacher zu interpretieren sind. Zudem kann die Nutzung relevanter Merkmale die Robustheit und Verlässlichkeit des trainierten Modells erhöhen. Sofern sich die Auswahl der Daten und Merkmale im späteren Projektverlauf als ungeeignet herausstellen sollte, kann diese Phase erneut durchschritten werden, um die Modellgüte iterativ zu verbessern oder sogar andere Algorithmen zu testen.

Phase 4

Stakeholder	 Geschäfts- verantwortliche*r	Leitfragen ▪ Welche Eingangs- und Ausgangsdaten hat das Modell? ▪ Welche Algorithmen stehen bei den gegebenen Eingangsdaten und den geforderten Ausgangsgrößen zur Verfügung? Was sind die jeweiligen Vor- und Nachteile? ▪ Beschränken die zur Verfügung stehenden Ressourcen (z. B. Rechenkapazität) die Auswahl der möglichen Algorithmen? ▪ Muss das Modell erklärbar sein? ▪ Wie sicherheitsrelevant sind die Modellentscheidungen? ▪ Für welchen Bereich der zu modellierenden Größe wird ein zuverlässiges Ergebnis benötigt? Wie zuverlässig muss das Modell sein? ▪ Wie kann die Zuverlässigkeit des Modells getestet werden? ▪ Ist das Modell statisch oder soll es sich kontinuierlich an neue Gegebenheiten anpassen? ▪ Können Simulationen zum Training des Modells herangezogen werden? ▪ Wie begrenzt ist die Modellierung unter Berücksichtigung des Datenschutzes? ▪ Müssen Daten anonymisiert werden? ▪ Kann eine ausreichende Genauigkeit erreicht werden, ohne die sensiblen Daten zu verwenden? ▪ Ist die Nutzung von Cloud-Lösungen für die Daten zulässig?
	 Technologie- Expert*in	
	 KI- Expert*in	
	 MLOps- Ingenieur*in	

Phase 4 – Das Herzstück: Die Modellierung

Nachdem ein Verständnis der Daten und Prozesse geschaffen wurde und die Daten vorbereitet und bereinigt wurden, geht es in dieser Phase um die Auswahl der geeigneten Algorithmen und die Erstellung von Modellen, um aus den gesammelten Daten den angestrebten Erkenntnisgewinn ableiten zu können. Hierzu gibt es eine Vielzahl von Algorithmen, die zur Bildung von Modellen geeignet sind.

Im VDMA-Quick-Guide „Machine Learning im Maschinen- und Anlagenbau“ [1] werden einige Programmiersprachen sowie Softwarebibliotheken und Frameworks, welche die Algorithmen als fertige Bausteine enthalten, exemplarisch eingeführt.

Ziel dieser vierten Phase ist, die geeigneten Modellierungstechniken auszuwählen, ein Testmodell zu erstellen und dieses mit Blick auf die Vorhersagegüte zu bewerten. Die wesentlichen Beteiligten sind hier die KI- und Domänen-Expert*innen, die bei der Auswahl der Parameter für die Modellierung und die Bewertung zusammenarbeiten. Oft werden die Parameter und Eingabedaten in dieser Phase in Folge der Bewertung justiert und es werden mehrere Modelle erstellt. Somit steht diese Phase in direktem Zusammenhang mit der vorhergehenden und kann auch iterativ durchlaufen werden. Je eindeutiger die Merkmale und die Zusammenhänge von Daten definiert und spezifiziert werden können, desto leichter kann das Modell solche Informationen in großen Mengen verarbeiten und ein zuverlässiges Ergebnis liefern. Die Sammlung von Daten sowie das Trainieren der algorithmischen Modelle sind jedoch zeit- und kostenaufwändig. Daher ist es empfehlenswert, mit einfachen Modellen zu beginnen, um eine Referenz für die Modellevaluierung zu schaffen.

Phase 5 – Die Wertschöpfung: Die Auswertung

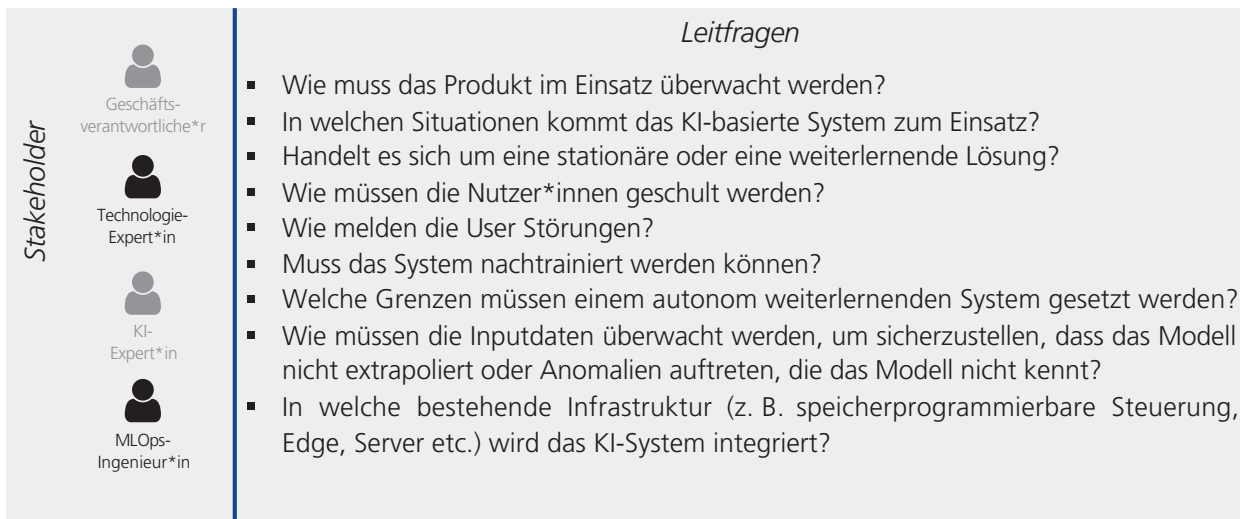
In der vorhergehenden Phase wurden ein oder mehrere Modelle erstellt und aus statistischer Sicht bewertet. In der Auswertungsphase sollte die Entscheidung getroffen werden, ob das ausgewählte Modell die in der ersten Phase definierten Erfolgskriterien und Anforderungen erfüllt oder ob eine neue Schleife eingezogen werden soll.

Vor der Bereitstellung des Modells ist es wichtig, dieses zu evaluieren und festzustellen, ob es die Geschäftsziele im Feld erreichen kann und die Auswirkungen der meist nicht vermeidbaren Fehlvorhersagen kompensierbar sind. Zusätzlich wird jeder Schritt zur Erstellung des Modells überprüft, bevor das Modell im Anschluss für den Einsatz im Betrieb freigegeben wird. Da der Praxisaspekt hier eine wichtige Rolle spielt, ist neben den KI-Expert*innen die Einbindung der geschäftsverantwortlichen Personen unerlässlich.

Phase 5

Stakeholder	Leitfragen
 Geschäfts- verantwortliche*r	
 Technologie- Expert*in	▪ Kann der erwartete Mehrwert anhand einer Pilotierung nachgewiesen werden? ▪ Welche kritischen Konstellationen aus dem Einsatz im Feld können bestehen und wie werden sie berücksichtigt?
 KI- Expert*in	▪ Wie groß könnte die Auswirkung eines fehlerhaften Outputs des Modells für das Unternehmen sein? ▪ Kann durch den Einsatz des Modells die wirtschaftliche Zielsetzung erreicht werden?
 MLOps- Ingenieur*in	▪ Sind weitere Iterationen und Anpassungen der vorherigen Phasen notwendig?

Phase 6



Phase 6 – Die geschaffene Lösung: Bereitstellung

Nach der Freigabe der erprobten Modelle für den Einsatz im Betrieb ist das Ziel dieser Phase, eine benutzerfreundliche und einsatzfähige Lösung bereitzustellen. Auch wenn die Lösung wesentlich auf Methoden aus dem Bereich der KI beruht, sollen bestehende Steuerungs- und Regelungssysteme nicht zwangsläufig substituiert werden, sondern die KI-Ansätze vielmehr in vorhandene Systeme und Plattformen eingebettet werden. Zentral für die Umsetzung sind Fragen nach der Funktion sowie der Bedienung und der Intervention durch die Nutzer*innen.

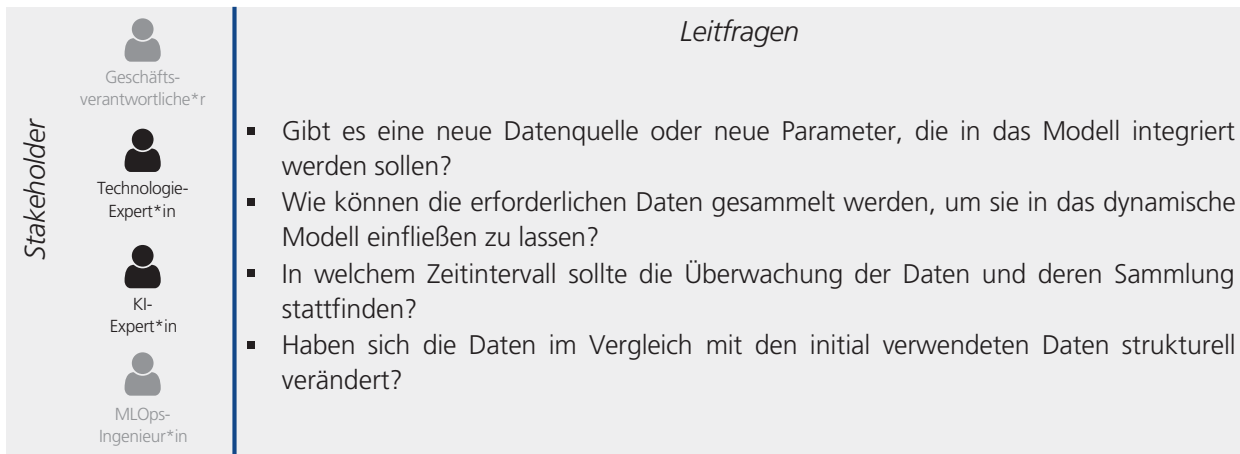
Dafür wesentlich ist die Expertise aus den Bereichen Softwareentwicklung und Systemadministration, die um das Technologieverständnis von Expert*innen zu ergänzen ist, um domänenspezifische Grenzen für das KI-System zu identifizieren und einen sicheren Rahmen für den Betrieb konzipieren zu können.

Phase 7 – Die Weiterentwicklung: Die fortlaufende Datensammlung

Der gestrichelte Kreis in Abbildung 25 beschreibt die Weiterentwicklung des Modells, nachdem es zum ersten Mal im Feld eingeführt wurde. Der erste Schritt in diesem inneren Kreis ist die Sammlung von Daten. Basierend auf dem Feedback aus dem Feld und auf den aus dem Modell gewonnenen Erkenntnissen lassen sich weitere Parameter und gegebenenfalls Datenquellen identifizieren, die das Modell ergänzen können.

Die siebte Phase beinhaltet die kontinuierliche Sammlung von Daten und die Überwachung hinsichtlich zusätzlicher relevanter Daten zur Erhöhung der Genauigkeit des Modells oder gegebenenfalls zu dessen Weiterentwicklung. Für diese Aufgaben sind die Domänen- und KI-Expert*innen als Hauptbeteiligte zuständig.

Phase 7



Phase 8

Stakeholder	Leitfragen
 Geschäfts- verantwortliche*r	▪ Welchen kritischen Situationen kann das KI-basierte System aufgrund einer Änderung der Inputdaten im Langzeiteinsatz ausgesetzt sein? ▪ Wie bzw. durch wen werden Störungen, die von Benutzenden gemeldet werden, behoben? ▪ Kann die KI stichprobenartig oder muss sie kontinuierlich überwacht werden? ▪ Wie können die Zyklen für ein Nachtrainieren der Modelle (Wartungsplan) bestimmt werden? ▪ Müssen die Grenzen, die einem autonom weiterlernenden System gesetzt wurden, angepasst werden? ▪ Wie kann sichergestellt werden, dass das Modell im Betrieb ausreichend effektiv und effizient auf die gegenwärtigen Inputdaten reagiert?
 Technologie- Expert*in	
 KI- Expert*in	
 MLOps- Ingenieur*in	

Phase 8 – Die fortlaufende Überprüfung: Die Wartung

Entsprechend der Konzeption der Funktion, der Bedienung und den Möglichkeiten zur Intervention durch die Nutzer*innen aus Phase 6 wird die Entwicklung über die vollständige Einsatzdauer hinweg in der Phase der Wartung überwacht. Während im Zuge der Bereitstellung konzeptionelle Aspekte aus den Bereichen Softwareentwicklung und Systemadministration im Mittelpunkt stehen, sind in der Wartung grundsätzlich die gleichen Aspekte hinsichtlich der Produkteigenschaften relevant – hier jedoch mit der zentralen Frage, wie vorgegangen werden muss, um diese zu überwachen. Der Kern der Arbeit setzt sich aus den Bereichen der **MLOps** zusammen, wobei die Sachkenntnis der Technologie-Expert*innen als Grundlage dient, um einzuschätzen, wie ein sicherer Betrieb gewährleistet werden kann. Das Wissen über die Architektur des KI-Systems erlaubt **MLOps-Ingenieur*innen**, ein Vorgehen zu entwickeln, um die Modelle geeignet nachzutrainieren, sobald das System außerhalb des definierten Betriebsrahmens agiert.

Als Ergebnis liegt am Ende dieser Phase ein Wartungsplan vor, aus dem hervorgeht, wie zu jeder Zeit ein sicherer Betriebszustand gewährleistet werden kann.

Das folgende Beispiel illustriert das vorgestellte Vorgehen anhand der Entwicklung eines automatisierten Qualitätsprüfungssystems. Die Abbildung 26 stellt die Hauptphasen des statischen Projektdurchlaufs und die wichtigsten Aktivitäten pro Phase dar. Ziel des vorgestellten Projektes war es, einen manuellen Sichtprüfprozess durch den Einsatz von Bilderkennung zu automatisieren, um die Mitarbeitenden von der Sichtprüfung zu entlasten und in Zukunft eine Korrelation zwischen Prozessparametern und Bauteilqualität zu ermöglichen.




Abbildung 26: Praxisbeispiel zur automatischen Qualitätssicherung transparenter Spritzgussbauteile
 (Quelle: OpenServ4P, Fraunhofer IGCv)

In Abbildung 27 ist ein weiteres Beispiel dargestellt, bei dem das Vorgehen zur Entwicklung eines Systems zur Echtzeit-Interpretation von Prozessdaten zur Vorhersage der Produkt-

qualität eingesetzt wurde. Ziel des vorgestellten Projektes war es, aufwändige, nachgelagerte Prüfschritte durch eine Inline-Analyse von Prozessdaten zu ersetzen.

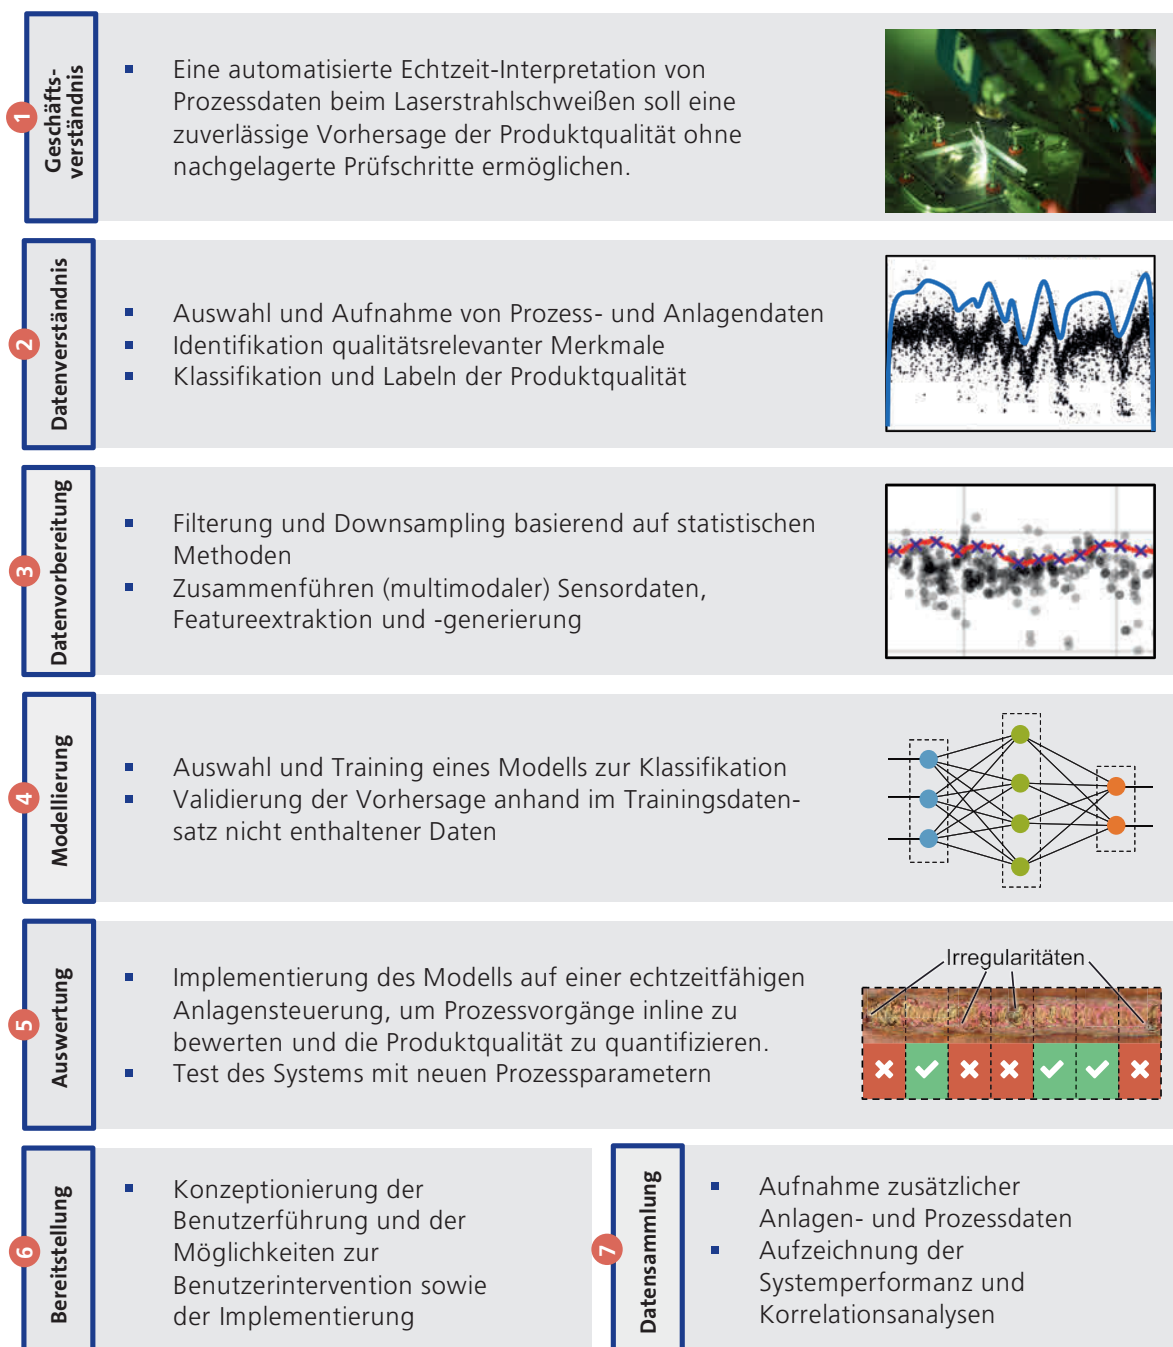


Abbildung 27: Praxisbeispiel zur automatisierten Echtzeit-Interpretation von Prozessdaten (Predictive Quality) beim Laserstrahlschweißen (Quelle: RoKtoLas, iwv TUM)

KI-Projekte dokumentieren

Der Erfolg von Projekten im Bereich der Künstlichen Intelligenz (KI) ist im Voraus oftmals nur schwer abzuschätzen, insbesondere wenn für den individuellen Anwendungsfall keine Erfahrungswerte zur Beurteilung der Datengrundlage und des gewählten Ansatzes vorliegen. Für KI-Projekte, in denen Unsicherheit bezüglich der aus den Daten extrahierbaren Informationen und des ableitbaren Wissens besteht, empfiehlt sich ein möglichst rascher Nachweis der Machbarkeit bzw. der Abbruch des Projekts im Falle einer unzureichenden Datengrundlage. Häufig sind es dabei domänen- oder methodenspezifische Herausforderungen und Feinheiten, die über die Realisierbarkeit datengetriebener Lösungen entscheiden.

Damit KI-basierte Lösungen langfristig einen positiven Beitrag zur Wirtschaftlichkeit von Geschäftsvorgängen und Produktionsabläufen beitragen können, ist eine sorgfältige Dokumentation – erfolgreicher wie nicht erfolgreicher Ansätze – von entscheidender Bedeutung. Damit ist eine Beurteilung der konkreten Herausforderungen und des Nutzens retrospektiv möglich und die gewonnenen Erkenntnisse können für folgende KI-Projekte genutzt werden. Auf Grundlage der Projektdokumentation sollten folgende zentralen Fragen beantwortet werden können:

- Welcher konkrete Nutzen konnte durch den Ansatz erreicht werden?
- Welches spezifische Problem wurde gelöst?
- Welche konkreten Herausforderungen mussten dafür gemeistert werden?

Ein KI-Projekt beinhaltet, wie im Kapitel zur Umsetzung erläutert, die Durchführung verschiedener Phasen in einem interdisziplinären Team, wobei einzelne Stakeholder teilweise nur für eine Phase zuständig sind. Daher hat eine gute und kontinuierliche Dokumentation im Laufe des Projekts einen hohen Stellenwert. Dies ist besonders für den internen Einsatz von hoher Bedeutung, zum Beispiel innerhalb des Projektteams, zwischen verschiedenen Abteilungen oder auch im Hinblick auf das Wissensmanagement und zukünftige Projekte. Abbildung 28 zeigt eine Vorlage für eine zweiseitige Dokumentation, die für die interne Dokumentation von KI-Projekten und als Orientierungshilfe für die ausführliche Projektdokumentation bzw. Dateiablage verwendet werden kann.

VDMA – Leitfaden Künstliche Intelligenz	Vorlage Projektdokumentation
Projektname 	Durchführung Kurze Beschreibung des Projektfortschritts anhand des Umsetzungsvorhabens für jede Phase im Laufe des Projekts
Projektlaufzeit von bis	
Projektbudget €	
Besetzte Projektrollen Projektleiter*in: Technologie-Expert*in: KI-Expert*in: MLOps-Ingenieur*in:	
Ausgangssituation und Zielsetzung Kurze Beschreibung der Ausgangssituation, Motivation und Zielsetzung	Ergebnisse Kurze Beschreibung der Ergebnisse, Rückblick auf die Ausgangssituation sowie Bewertung des Nutzens, der durch das Projekt erreicht wurde







Abbildung 28: zweiseitige Vorlage zur Dokumentation des KI-Projekts (erste Seite)

VDMA – Leitfaden Künstliche Intelligenz

Vorlage Projektdokumentation

Einordnung des Projekts

	Marketing, Vertrieb & Service	Produkt- entwicklung	Supply Chain Management & Einkauf	Produktions- steuerung & Intralogistik	Produktions- prozess	Qualitäts- sicherung	Bereichs- übergreifend
Beurteilen							
Schlussfolgern							
Reagieren							

Ausgefülltes Business Model Canvas

Nutzen			
Vormessage	Verifikation	Aktion	Wirksamkeit
Daten		Training	Optimierung

Gewonnene Erkenntnisse

Kurze Beschreibung der Herausforderungen, der daraus gewonnenen Erkenntnisse sowie des Verbesserungspotenzials im Hinblick auf Folgeprojekte

Zusammenfassung und Ausblick

Zusammenfassung des Projekts in Fakten und Zahlen und Beschreibung möglicher nächster Schritte (ggf. Folgeprojekte)



Fraunhofer
IGCV

Abbildung 28: zweiseitige Vorlage zur Dokumentation des KI-Projekts (zweite Seite)

Im Folgenden werden die einzelnen Felder der Projektdokumentationsvorlage kurz erläutert. Die ersten vier Felder umfassen die Eckdaten des Projekts: Name, Laufzeit, Budget sowie beteiligte Personen und deren Rollen.

Im Feld „Ausgangssituation und Zielsetzung“ sollten zunächst die Ist-Situation sowie die bei Projektstart vorhandenen Probleme und Herausforderungen kurz beschrieben werden. Des Weiteren sind hier die Ziele zu dokumentieren, die zu Beginn des Projekts festgelegt wurden. Diese werden in der Regel in der ersten Phase des Projekts bei der Identifizierung des Anwendungsfalls definiert und sollten bestenfalls quantifizierbar sein.

Der schrittweise Verlauf des Projekts während der gesamten Projektlaufzeit sollte im Feld „Durchführung“ festgehalten werden. Hierfür eignet sich das vorgestellte 8-Schritte-Vorgehensmodell zur Orientierung. Relevante Informationen sind hier beispielsweise, welche Algorithmen untersucht wurden, wie viele Iterationen durchgeführt wurden, um die Modellqualität zu erreichen, und wie lange die Datenaufbereitung und -bereinigung gedauert hat. Es ist empfehlenswert, dieses Feld während des Projekts aktiv zu nutzen und nicht erst nach Projektabschluss mit einer Dokumentation zu beginnen.

Das Feld „Ergebnisse“ bezieht sich im Vorgehensmodell auf die fünfte Phase des Projekts, die Auswertung, und dient zur retrospektiven Bewertung des Projekts. Hier wird die kritische Beurteilung der Projektergebnisse dokumentiert, die auch im besten Fall quantitativ erfasst und mit den zu Beginn des Projekts definierten Zielen verglichen wird.

Das Ziel des Feldes „Einordnung des Projekts“ ist es, das Projekt anhand der drei grundlegenden Fähigkeiten von KI-Systemen – Beurteilen, Schlussfolgern und Reagieren – und des betroffenen Unternehmensbereichs prägnant zu klassifizieren. Dies kann dazu beitragen, ähnliche Projekte zu identifizieren, ohne die gesamte Projektdokumentation im Detail lesen zu müssen.

Im nächsten Feld sollte das ausgefüllte Business Model Canvas dokumentiert werden. Dieses muss zu Beginn des Projektes zur Bewertung der Anwendungsfälle verfasst werden und bietet einen komprimierten Überblick über die diskutierten Themen wie Nutzen, Datenverfügbarkeit, Datenqualität und Wirksamkeit der Aktionen des KI-Systems im Projekt.

Die letzten beiden Felder zielen darauf ab, das Projekt zusammenzufassen und einen Einblick für die zukünftigen Projekte zu vermitteln. Unter „Gewonnene Erkenntnisse“ werden die Herausforderungen und Fallstricke beschrieben, die während des Projekts aufgetreten sind und gemeistert wurden. Im letzten Feld wird das Projekt, gegebenenfalls in Zahlen, zusammengefasst. Zusätzlich werden hier Handlungsempfehlungen für Entscheidungsgremien dokumentiert und Hinweise auf mögliche Weiterentwicklungen der Lösung oder die Identifizierung eines Folgeprojektes festgehalten.

Zusammenfassung und Ausblick

Durch den Leitfaden sollen deutsche Unternehmen in ihren ersten Schritten im Bereich der Künstlichen Intelligenz (KI) unterstützt werden. Vor allem die Ansätze des Maschinellen Lernens bieten eine Vielzahl neuer Anwendungsmöglichkeiten, welche längst aus der Forschung kommend Einzug in die Industrie gefunden haben. Ähnlich wie Arbeiten aus dem Bereich der Steuerung und Regelung von Maschinen früher noch unter dem Begriff der „Kybernetik“ als Teilgebiet der Künstlichen Intelligenz betrachtet wurden und heute zum Basiswissen von Maschinenbaustudierenden gehören, entwickelt sich auch das Maschinelle Lernen zu einem zusätzlichen Werkzeug für den Maschinen- und Anlagenbau.

Die zahlreichen im Leitfaden vorgestellten Praxisbeispiele können nur einen Teilbereich der möglichen Anwendungen abdecken, welche schon heute einen Mehrwert in kleinen und mittelständischen Unternehmen bringen können. Jedoch sollen sie einen Anhaltspunkt geben, um beispielsweise innerhalb des skizzierten Workshops zur Identifikation von KI-Potenzialen neue Ideen anzuregen. Gerade zu Beginn mangelt es allerdings oftmals noch an der notwendigen Expertise, um ein KI-Projekt selbstständig umzusetzen. Mithilfe des Kapitels zur Umsetzung von KI-Projekten kann allerdings abgeschätzt werden, welche Projektphasen gemeinsam mit externen Dienstleistern durchlaufen werden müssen und welche Arten der Expertise erforderlich sind bzw. für zukünftige Eigenentwicklungen aufgebaut werden müssten.

Die abgebildeten Anwendungsfälle sind zudem nur eine Momentaufnahme der aktuellen Möglichkeiten von Künstlicher Intelligenz. Jedes Jahr kommen neue Ansätze hinzu, um die Anwendung maschineller Lernverfahren zu vereinfachen und deren Fähigkeiten zu erweitern.

So bildet beispielweise Reinforcement Learning (siehe VDMA-Leitfaden „Selbstlernende Produktionsprozesse“ [5]) eine neue Möglichkeit, Prozesse zu steuern, welche für konventionelle Methoden zu komplex wären. Zum Einsatz kommen kann dieses Verfahren u. a. in der robusten Handhabung unterschiedlichster Bauteile, in der Optimierung komplexer Maschinen oder im dynamischen Job-Shop Scheduling. Auch in der Verarbeitung natürlicher Sprache wurden in den vergangenen Jahren enorme Fortschritte verzeichnet und so können KI-Systeme zunehmend auch mit unstrukturiertem Wissen aus Dokumenten arbeiten oder gar ganze Artikel (z. B. Produktbeschreibungen) selbstständig verfassen.

Strukturiertes Wissen wird zunehmend nicht in Form starrer Datenbanken, sondern mit flexiblen semantischen Modellen wie z. B. Wissensgraphen erfasst. Dies ermöglicht die nahtlose Kombination von datenbasierten Modellen mit Domänenwissen der Expert*innen. Zusätzlich werden bestehende Ansätze stetig weiterentwickelt, wodurch maschinelle Lernverfahren weniger Daten benötigen (z. B. durch One-/Few-Shot Learning, Transfer Learning) und einfacher einsetzbar werden (z. B. durch Automated Machine Learning).

Es lohnt sich daher bereits jetzt, das eigene Unternehmen auf den Einsatz von Künstlicher Intelligenz auszurichten und in ersten Projekten Erfahrungen zu sammeln.

Projektpartner / Impressum

Herausgeber

VDMA
Bayern
Denninger Straße 84
81925 München
Telefon +49 89 278287-60
E-Mail bayern@vdma.org
Internet bayern.vdma.org

Fraunhofer-Institut für Gießerei-,
Composite- und Verarbeitungstechnik IGCV
Marcus Röhler
Am Technologiezentrum 10
86159 Augsburg
Telefon +49 821 90678-148
E-Mail marcus.roehler@igcv.fraunhofer.de
Internet igcv.fraunhofer.de

Institut für Werkzeugmaschinen und Betriebswissenschaften (iwb),
Technische Universität München
Sajedeh Haghi
Boltzmannstr. 15
85748 Garching b. München
Telefon +49 89 289 154 36
E-Mail sajedeh.haghi@iwb.tum.de
Internet www.iwb.mw.tum.de

Projektleitung

VDMA Bayern, Michael Schalk

Inhaltliche Beiträge

Fraunhofer-Institut für Gießerei-,
Composite- und Verarbeitungstechnik IGCV
Marcus Röhler

Institut für Werkzeugmaschinen und Betriebswissenschaften (iwb),
Technische Universität München
Sajedeh Haghi

Beteiligte Unternehmen in der Arbeitsgruppe:

- asimovero.AI
- Baumüller Anlagen-Systemtechnik GmbH & Co. KG
- Chr. Mayr GmbH + Co. KG
- DEPRAG SCHULZ GMBH u. CO.
- iteratec GmbH
- Kiefel GmbH
- KraussMaffei Technologies GmbH
- Martin GmbH für Umwelt- und Energietechnik
- MVTec Software GmbH
- Siemens AG
- Technologisches Institut für angewandte Künstliche Intelligenz GmbH
- The MathWorks GmbH
- XITASO GmbH

Design und Layout

VDMA DesignStudio
Erscheinungsjahr 2020

Druck
Druck- und Verlagshaus
Zarbock GmbH & Co. KG

Copyright

VDMA Bayern

Bildnachweise

Titelbild: © Shutterstock
Seite 4: © StMWi
Seite 5: Fraunhofer-Institut für Gießerei-,
Composite- und Verarbeitungstechnik IGCV, Institut für
Werkzeugmaschinen und Betriebswissenschaften (iwb)
Seite 6: VDMA

Grafiken

Fraunhofer-Institut für Gießerei-,
Composite- und Verarbeitungstechnik IGCV

Institut für Werkzeugmaschinen und
Betriebswissenschaften (iwb)
Technische Universität München

Literaturverzeichnis

- [1]
VDMA Software und Digitalisierung: Quick Guide.
Machine Learning im Maschinen- und Anlagenbau, 2018.
- [2]
Russel, S.; Norvig, P.: Künstliche Intelligenz. Ein moderner
Ansatz, Pearson Studium, 2012.
- [3]
High-Level Expert Group der Europäischen Kommission:
A Definition of AI – Main Capabilities and Disciplines, 2019.
- [4]
High-Level Expert Group der Europäischen Kommission:
Assessment List for Trustworthy Artificial Intelligence
(ALTAI) for Self-Assessment, 2020.
- [5]
VDMA Forum Industrie 4.0: Leitfaden Selbstlernende
Produktionsprozesse. Einführungsstrategie für Reinforcement
Learning in der industriellen Praxis, 2019.

Hinweis

Die Verbreitung, Vervielfältigung und öffentliche Wiedergabe
dieser Publikation bedarf der Zustimmung des VDMA und seiner
Partner. Auszüge der Publikation können im Rahmen des Zitatrechts
(§ 51 Urheber- rechtsgesetz) unter Beachtung des Quellenhinweises
verwendet werden.

Weitere Ressourcen



VDMA
Bayern

Denninger Straße 84
81925 München
Telefon +49 89 278287-60
E-Mail bayern@vdma.org
Internet bayern.vdma.org

**Fraunhofer-Institut für Gießerei-,
Composite- und Verarbeitungstechnik IGCV**

Marcus Röhler
Am Technologiezentrum 10
86159 Augsburg
Telefon +49 821 90678-148
E-Mail marcus.roehler@igcv.fraunhofer.de
Internet igcv.fraunhofer.de

**Institut für Werkzeugmaschinen und
Betriebswissenschaften (iwb),
Technische Universität München**

Sajedeh Haghi
Boltzmannstr. 15
85748 Garching b. München
Telefon +49 89 289 154 36
E-Mail sajedeh.haghi@iwb.tum.de
Internet iwb.mw.tum.de



www.vdma.org