

Whitepaper

---

## Künstliche Intelligenz in der Einzel- und Kleinserienfertigung



# Inhalt

---

<b>Künstliche Intelligenz</b> .....	<b>4</b>
Großes Potenzial für Einzelfertigung und Kleinserie .....	4
Automated Machine Learning in der Produktion .....	6
Eignet sich künstliche Intelligenz für meinen Anwendungsfall? .....	10
<b>KI-Prozesse</b> .....	<b>12</b>
Datenvorverarbeitung sichert die Datenqualität .....	12
Datenbasierte Prozessoptimierung .....	14
KI-gestützte Datenanalyse für eine automatisierte Planung .....	15
Zertifizierung KI-unterstützter Prozesse und Produkte .....	16
<b>Beispiele aus der Anwendung</b> .....	<b>18</b>
Werkzeugverschleiß durch Körperschall erkennen .....	18
Deep Learning zur optischen Erkennung von Werkzeugverschleiß .....	19
Das CAM-System der Zukunft .....	20
Qualitätsvorhersage in der Produktion .....	22
<b>Zusammenfassung</b> .....	<b>24</b>
<b>Glossar</b> .....	<b>25</b>
<b>Referenzen</b> .....	<b>26</b>

# Künstliche Intelligenz

---

## Großes Potenzial für Einzelfertigung und Kleinserie

**Der exponentielle Anstieg der Rechenleistung von Computern hat dazu geführt, dass die klassisch-regelbasierte Programmierung abgelöst wird durch Systeme mit Künstlicher Intelligenz, kurz: KI, – also durch Programme, die Informationen aus ihrer Umwelt wahrnehmen und verarbeiten, Probleme selbstständig lösen, Entscheidungen treffen, handeln und aus den Ergebnissen dieser Aktivitäten lernen [1].**

Ziel beim Einsatz von KI ist, dass die Programme dem Menschen nicht nur Vorschläge für Entscheidungen oder Maßnahmen unterbreiten, sondern diese auch selbstständig umsetzen. Auf diese Weise könnte die Steuerung von Anlagen und Prozessen deutlich effizienter und damit günstiger werden. Das impliziert jedoch auch die Erwartung an das System, auf Veränderungen flexibel zu reagieren und selbstständig die richtigen Schlussfolgerungen zu ziehen.

Während KI bereits viele Anwendungen im Alltag unterstützt, beispielsweise in Gestalt von Übersetzungsprogrammen oder persönlichen Sprachassistenten, kommt sie in der Produktion noch kaum zur Anwendung. Dabei verbirgt sich gerade hier ein besonders großes Potenzial: Nennenswerte Produktivitätszuwächse in produzierenden Unternehmen sind nur noch von Technologieinnovationen – wie KI – zu erwarten, denn die heute schon vielfach eingesetzten Methoden zur Rationalisierung wie Lean Production oder kontinuierliche Verbesserungsprozesse sind bereits weitgehend ausgereizt.

Dies verdeutlicht auch eine Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi), der zufolge in Deutschland im produzierenden Gewerbe innerhalb der nächsten fünf Jahre mit einer zusätzlichen Bruttowertschöpfung von etwa 31,8 Milliarden Euro durch den Einsatz von KI zu rechnen ist. Vor allem die KI-Anwendungen rund um Predictive Analytics, intelligente Assistenzsysteme und intelligente Automatisierung gelten dabei sowohl unter Anwendern als auch unter Anbietern von KI als vielversprechend [2]. Für den Einsatz von KI in der Produktion spricht weiterhin, dass die Produktionsumgebungen seit Jahren vor dem Hintergrund der vierten Industriellen Revolution (Industrie 4.0) digitalisiert werden. Dieser Vorgang, Daten für Computer lesbar und verarbeitungsfähig zu machen, ist die Grundvoraussetzung, um daraus Informationen, Wissen und Entscheidungen abzuleiten.

Die vollständig adaptive Produktion – Stichwort: Smart Factory – bleibt dabei zwar bislang meist noch unerreicht, aber viele Unternehmen sammeln bereits jetzt größere Datenmengen an, aus denen sich prinzipiell Erkenntnisse ableiten ließen. Um KI jedoch effektiv zu nutzen, spielen neben der Menge an Daten auch die Qualität und Verfügbarkeit eine Rolle. In der Praxis fehlt es hier häufig noch an homogenen und durchlässigen Datenstrukturen. Sobald diese Systemvoraussetzungen erfüllt sind, können KI-Technologien Produktivitätskennzahlen jedoch signifikant verbessern. Zu erwarten sind dann beispielsweise Steigerungen der Fertigungserträge um rund 30 Prozent sowie kürzere Ausfallzeiten und geringere Ausschusskosten von jeweils circa 20 Prozent [3]. Allerdings findet die Technologie in der Praxis nur sehr zögerlich Anwendung.

Umfragen zufolge verfügt ein Großteil der Unternehmen (78 Prozent) allenfalls über grundlegende Erfahrungen mit dem Einsatz von KI [4]. Die Implementierung wird sich zwar voraussichtlich innerhalb der kommenden Jahre stark beschleunigen, doch fällt es heute vielen Entscheidern noch schwer, die Potenziale der Technologie für ihr Unternehmen zu erkennen und geeignete Anwendungsfälle abzuleiten [5].

Die größten Herausforderungen im Hinblick auf einen effektiven Einsatz von KI in produzierenden Unternehmen sind daher die Folgenden:

1. Zumeist stehen die relevanten Daten weder in ausreichender Menge und Qualität zur Verfügung, noch existiert eine Systeminfrastruktur, um diese optimal zu verarbeiten.
2. Vielen Entscheidern fehlt es noch an ausreichendem Verständnis der Technologie und der dahinterliegenden Konzepte. Daher scheuen sie davor zurück, den Einsatz von KI in ihren Verantwortungsbereichen zu evaluieren oder zu erproben.
3. Die Anwendungsfälle für KI sind bisher nur in geringem Umfang bekannt. Dies erschwert eine Prognose des möglichen Nutzens für Entscheider zusätzlich.

Das vorliegende Whitepaper beleuchtet zunächst die Technologie an sich und geht dann auf ihre Einsatzgebiete im Werkzeugbau und anderen fertigenden Unternehmensbereichen ein. Damit möchten wir vor allem kleinen und mittleren Unternehmen einen tieferen Einblick die Möglichkeiten der Technologie bieten, den Wissenstransfer mit Blick auf die geplanten Aktivitäten erleichtern und sie bei Interesse dabei unterstützen, zeitnah und zielgerichtet eigene Pilotprojekte zu starten.

**Autorin** Leonie Krebs

### **Künstliche Intelligenz (KI)** beziehungsweise **Artificial Intelligence (AI)**

---

ist der Überbegriff für Anwendungen, bei denen Maschinen menschenähnliche Intelligenzleistungen erbringen. Das Feld KI umfasst beispielsweise Methoden zum Lernen aus Daten, zur Schlussfolgerung und zur Selbstkorrektur.

# Automated Machine Learning in der Produktion

Die Automatisierung des maschinellen Lernens bietet die Möglichkeit, manuelle Tätigkeiten bei der Entwicklung einer KI zu automatisieren. Eine spezielle Herausforderung in der Produktion liegt darin, diese Automatisierung so zu gestalten, dass das entsprechende Domänenwissen in die KI-Anwendungen einfließt und alle damit verbundenen Anforderungen so weit wie möglich berücksichtigt werden.

Der am häufigsten verwendete Ansatz, um KI-Systeme zu entwickeln, ist die Anwendung des maschinellen Lernens (ML): Die so genannte »ML-Pipeline« ist in Abbildung 1 dargestellt.

Indem die Prozesse der ML-Pipeline durchlaufen werden, lassen sich neue Informationen und damit Wissen gewinnen – so, wie es oft in Data-Mining-Projekten geschieht. Andererseits ist die ML-Pipeline ein zentrales Element in der Ausbildung einer Künstlichen Intelligenz (KI), die versucht, durch Nachahmen menschlichen Verhaltens Aktionen abzuleiten.

In den vergangenen Jahren konnten immer mehr Unternehmen erfolgreich Projekte unter Einsatz von Machine Learning oder sogar Künstlicher Intelligenz durchführen. Oft wird hier jedoch verschwiegen, dass im Prozess zwischen dem Sammeln von Rohdaten und dem Einsatz des trainierten Modells einige Hürden zu überwinden sind:

- Eine hohe Anzahl manueller Tätigkeiten, vor allem bei der Bereinigung und Vorverarbeitung der Daten,
- ein hoher Zeitaufwand bei der Auswahl und Abstimmung des Algorithmus,
- die Verfügbarkeit von Fachwissen zum Durchlaufen aller Phasen der Pipeline und
- Zugriff auf Data Scientists, die diese Phasen durchlaufen können, die bisher auf dem Arbeitsmarkt noch wenig vorhanden und gleichzeitig sehr gefragt sind.

Ein neuer Ansatz, der erstmals im Jahr 2014 eingeführt wurde [6], aber seit 2019 an Popularität gewinnt, ist das Automatisierte Maschinelle Lernen (AutoML) [7]. AutoML bezieht sich auf den Prozess der Automatisierung einiger oder aller Teile der ML-Pipeline.

Ziel ist es, den Aufwand für den Benutzer, der die Daten zur Verfügung stellt, möglichst gering zu halten. Dafür bestimmt das AutoML-System automatisch eine Vorgehensweise, die für diese spezielle Anwendung am besten geeignet ist. Der Data Scientist führt damit keine manuellen Tätigkeiten aus, sondern wählt nur noch die passenden Parameter der ML-Pipeline aus. Auf diese Weise wird ML auch für Nicht-Programmierer verfügbar, da es den Aufwand von der Datenaufbereitung bis zu einem trainierten Modell minimiert – unabhängig von der jeweiligen Lernaufgabe. Die Vorteile der Automatisierung des maschinellen Lernens sind also:



Abbildung 1: Klassischer Prozess der Anwendung des maschinellen Lernens, auch bekannt als »ML-Pipeline« im Vergleich zu AutoML

- Eine schnelle Implementierung von Lösungen für maschinelles Lernen ohne umfangreiche Programmierkenntnisse und damit eine »Demokratisierung von ML«, da mehr Menschen Zugang erhalten.
- Eine höhere Zeit- und Ressourceneffizienz als bei einer manuellen ML-Pipeline.
- Best Practices aus den Datenwissenschaften können in ein AutoML-System integriert werden, sodass sich manuelle Fehler reduzieren und die Gesamtleistung verbessert wird.
- Geeignete Auto-ML-Systeme können neue Modelle in kurzen Zeitabständen erstellen, damit verschiedene Modelle in kürzerer Zeit getestet werden können und das Vorgehen zur Problemlösung dadurch agiler wird.
- Datenwissenschaftler können sich auf die kreativen Aufgaben in ML-Projekten konzentrieren, anstatt wenig herausfordernde manuelle Tätigkeiten zu verrichten.

## Die AutoML-Pipeline für die Produktion

Die bestehenden Ansätze zur Anwendung von AutoML versuchen, einen sehr allgemeinen Überblick zu geben und berücksichtigen nicht die speziellen Anforderungen der Produktion [8].

Um diese einzubeziehen, entwickelte das Fraunhofer IPT eine AutoML-Pipeline, die einen Überblick über die notwendigen Operationen bietet und die jeweiligen Akteure benennt, die für die Durchführung der Prozesse gefordert werden – sowohl Datenwissenschaftler als auch Produktionsexperten (Abbildung 2). Die Pipeline ist so konzipiert, dass sie für die meisten ML-Projekte in der Produktion geeignet ist.

Obwohl er für erfolgreiche ML-Projekte von entscheidender Bedeutung ist, wird der Schritt der Datenintegration oft vernachlässigt. Dies ist schwerwiegend, weil Unternehmen die Integration normalerweise als eine große Herausforderung ansehen, wenn sie beginnen, Interesse an ML zu entwickeln. Gewöhnlich stammen die relevanten Informationen für ein bestimmtes Projekt aus mehreren verschiedenen Datenquellen und die Datenstrukturen unterscheiden sich stark, sodass die Zusammenführung der Daten sehr herausfordernd ist. Entsprechend der bereits etablierten Definition für Datenbanken [9] kann die Datenintegration als Problem verstanden werden, Daten aus verschiedenen Quellen zu kombinieren und ein für die Entwickler zugängliches Datenobjekt bereitzustellen.

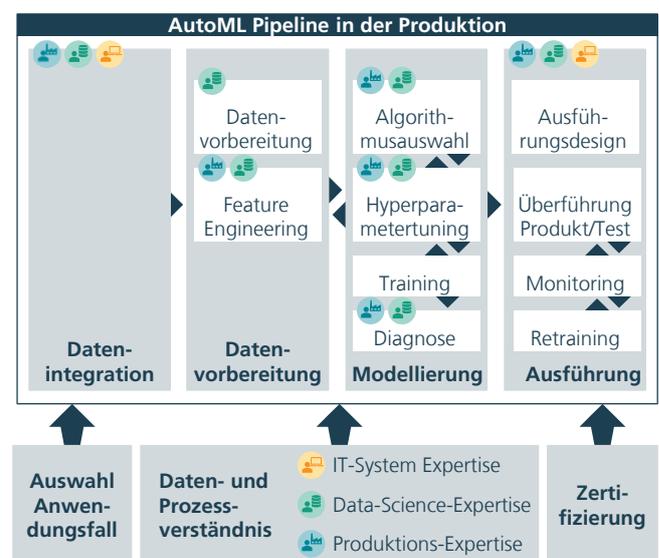


Abbildung 2: AutoML-Pipeline

## Hyperparameter

---

Als Hyperparameter werden solche Machine Learning Parameter bezeichnet, die nicht aus den vorliegenden Trainingsdaten erlernt, sondern manuell angegeben werden. Darunter fallen alle Parameter, die den Lernprozess selbst steuern (Lernrate, Abbruchkriterium, etc.). Im Falle neuronaler Netze fällt darunter auch die Architektur des neuronalen Netzes (Anzahl Schichten, Anzahl Neuronen pro Schicht, etc.).

## Hyperparameter-Tuning

---

Das Hyperparameter-Tuning bezeichnet die Optimierung von Hyperparametern bezüglich der Trainings-Zielfunktion.

Während der Datenvorverarbeitung wird ein Datensatz erzeugt, der für die spätere Modellbildung genutzt werden kann. Hier handelt es sich um einen entscheidenden Schritt für die Anwendung von ML [10]. Durch gezielte Datenoperationen wird so die Datenqualität verbessert [11]. »Feature Engineering« beschreibt eine Vorberechnung von Merkmalen die die Wissensextraktion durch einen ML-Algorithmus erleichtert.

Die Modellierung deckt die grundlegenden ML-Aufgaben ab: Die Generierung eines Modells, das die Anforderungen erfüllt und einen qualitativ hochwertigen Datensatz mit relevanten Merkmalen liefert. Die ersten drei Prozesse innerhalb der Modellierung sind die Algorithmusauswahl, die Hyperparameter-Optimierung (HPO) und das Training. Hier wird der der ML-Algorithmus ausgewählt, implementiert und ausgeführt, um das Modell zu generieren. Die ersten drei Prozesse können zum sogenannten »Combined Algorithm Search and HPO Problem« (CASH) zusammengefasst werden [12]. Diese Operationen durchlaufen in den meisten Fällen mehrere Iterationen, die oft Anpassungen des Datensatzes erfordern, und sind in der Abbildung durch die Rückkopplungsschleifen dargestellt. Den Abschluss der Modellierung bildet der Diagnoseprozess: Er schließt die Lücke zwischen der Leistung eines Modells und seinem Verständnis, da die Ergebnisse eines erfolgreichen ML-Projekts für die Fachexperten, in diesem Fall aus der Produktion, verständlich sein sollten [13]. Um die erzielten Ergebnisse für den Anwender zugänglich zu machen, wird das Modell im letzten Schritt dem Endbenutzer bereitgestellt.

Für ein erfolgreiches Projekt reicht es jedoch nicht aus, nur die vier Phasen der AutoML-Pipeline durchlaufen zu haben: Ohne die Auswahl der vielversprechendsten ML- und KI-Anwendungsfälle könnte ein Projekt entweder an einem Mangel an ausreichenden Daten oder an unrealistischen Erwartungen der Unternehmensleitung oder der Endbenutzer scheitern. Vor allem der Black-Box-Charakter einiger Lösungen sowie die Funktionsumfänge der entwickelten Lösungen, können »Show Stopper« sein.

## Vorteile, Grenzen und Entwicklungen von AutoML in der Produktion

AutoML-Systeme bieten die Möglichkeit, die Effizienz von ML-Projekten zu verbessern, indem sie notwendige Operationen innerhalb der Datenintegration, Datenvorverarbeitung, Modellierung und Deployment automatisieren. Erste AutoML-Systeme, die bereits mehrere Schritte der ML-Pipeline umfassen, sind auf dem Markt erhältlich, aber kein System deckt die gesamte ML-Pipeline ab.

Selbst für bestimmte Schritte innerhalb der ML-Pipeline, wie die Modellierung, ist der so genannte »happy path« von AutoML schmal: AutoML zeigt eine schlechte Leistung sowohl beim unüberwachten Lernen (unsupervised learning) als auch beim bestärkenden Lernen (reinforcement learning) und hat Schwierigkeiten bei der Handhabung komplexer Datentypen. Die Modelldiagnose ist aufgrund der erforderlichen Fachkenntnisse noch nicht gut automatisiert.

Daher ist es wichtig, sowohl datenwissenschaftliche Expertise als auch Anwendungswissen aus der Produktion einzubeziehen, um zufriedenstellende Ergebnisse zu erzielen. Dies bildet die Grundlage für die weitere Verbesserung der Schritte der Datenintegration und Datenaufbereitung. Im Vergleich zu den anderen Schritten ist der Grad der technologischen Reife von AutoML-Systemen für die Modellierung am höchsten. Dennoch kann auch die Auswahl der Algorithmen durch die Einbringung von domänenspezifischem Expertenwissen weiter verbessert werden – zum Beispiel aus vergangenen Projekten. Die Einbeziehung von domänenspezifischem Wissen könnte durch die Einbeziehung von Expertensystemen, domänenspezifischen Sprachen (DSL) oder Wissensgrafiken erreicht werden.

Die bisherigen Entwicklungen im Bereich der AutoML zeigen, dass Fortschritte in Richtung einer Automatisierung einzelner Schritte innerhalb der ML-Pipeline zu erwarten sind. Insgesamt ist eine vollständige Automatisierung der gesamten ML-Pipeline von der Datenintegration bis zum Einsatz ein Konzept, das weiterer Forschung bedarf. In naher Zukunft ist zu erwarten, dass Aufgaben wie die Modellierung so weit automatisiert werden, dass ML-Modelle mit wenig bis gar keinem ML-Wissen erstellt werden können. In Zukunft kann auch mit Semi-AutoML-Systemen gerechnet werden, die Data Scientists bei ihren Entscheidungen unterstützen.

**Autoren** Jonathan Krauß | Maik Frye

### Unsupervised Learning

Als Unsupervised Learning (unüberwachtes Lernen) bezeichnet man eine Klasse von Methoden des maschinellen Lernens, die zum Ziel haben, Muster und Strukturen innerhalb unbeschrifteter Eingabedaten zu ermitteln. Anders als beim Supervised Learning (überwachtes Lernen) sind hier keine Zielgrößen wie Klassenlabel oder Regressanden vorgegeben. Beispiele für unüberwachtes Lernen sind die Clusteranalyse und die Schätzung der den Daten zugrunde liegenden Wahrscheinlichkeitsverteilung.

### Reinforcement Learning

Das Reinforcement Learning (bestärkendes Lernen) bezeichnet eine Klasse von Methoden des maschinellen Lernens, bei denen eine Aktionssequenz gefunden werden soll, die eine kumulative Belohnungsfunktion maximiert. Ein Agent führt dabei Aktionen aus, die zu Zustandsänderungen führen und wiederum mit positiven (bestärkenden) oder negativen Belohnungen verbunden sind. Nach anfänglich zufälligen Aktionen soll der Agent mit der Zeit lernen vorherzusagen, welche Aktion mit welcher Wahrscheinlichkeit zu welcher Zustandsänderung führt und mit welcher Belohnung dies verbunden ist. Nach der Trainingsphase wird auf Basis des trainierten Vorhersagemodells eine Aktionsfolge gewählt, die die Summe der erwarteten Belohnungen maximiert.

# Eignet sich künstliche Intelligenz für meinen Anwendungsfall?

Für die Entscheidung, ob eine Anwendung sich für den Einsatz Künstlicher Intelligenz eignet, sind strategische, wirtschaftliche, technische und organisatorische Gesichtspunkte zu berücksichtigen.

## Welche Aufgaben durch Künstliche Intelligenz profitieren

Künstliche Intelligenz lässt sich bereits heute sinnvoll in der Produktion einsetzen: um Prozesse zu überwachen und effizienter zu gestalten, Routinetätigkeiten zu übernehmen und bei Entscheidungen zu unterstützen. Für den produzierenden Mittelstand gilt es, die Entwicklungen und Potenziale von KI im Auge zu behalten. Vielen Unternehmen fehlen allerdings das Fachwissen und die Erfahrung, um die Chancen realistisch einzuschätzen und bei einer positiven Entscheidung für KI eigenständig die ersten Schritte hin zu einer intelligenteren Fertigung zu gehen.

Um in einer technologisch bereits hochoptimierten Fertigung heute noch weitere Produktivitätssteigerungen zu erzielen scheint der Einsatz von KI für die Zukunft neue Wege zu eröffnen. Gerade kleine und mittlere Unternehmen stehen heute vor der Aufgabe, KI im Hinblick auf das eigene Geschäftsmodell für sich zu prüfen und dort, wo sie die eigene Wettbewerbsfähigkeit stärken kann, zu vertretbaren Kosten umzusetzen.

Drei Fraunhofer-Institute bündeln nun ihre Kompetenzen im Bereich der KI und der Produktion und bieten dem Management produzierender Unternehmen einen strukturierten Einstieg in die komplexe Thematik: Zusammen mit anderen Instituten der Fraunhofer-Allianz Big Data und Künstliche Intelligenz bietet das Fraunhofer IPT produzierenden Unternehmen an, ihr Fachwissen aus der produktionsbezogenen Forschung zum Thema Künstliche Intelligenz in deren Geschäftspraxis einzubringen. Dazu haben die Forscherinnen und Forscher im interdisziplinären Verbund das »AI Kick-Starter Bundle« entwickelt (Abbildung 3).

Zentrale Komponenten der Methodik sind:

- Identifikation und Priorisierung strategischer Ziele von KI-Aktivitäten
- Entwicklung möglicher KI-Anwendungen
- Bewertung der technischen und wirtschaftlichen Machbarkeit
- Roadmapping für den Weg zum Einsatz von KI im Unternehmen

Das konkrete Vorgehen ist dreistufig: Zusammen mit der Unternehmensleitung legen die Fraunhofer-Forscher strategische Ziele für den Einsatz der KI-Systeme im Unternehmen fest, erarbeiten konkrete Einsatzgebiete und prüfen in einer ganzheitlichen Betrachtung, welche Kriterien zu erfüllen sind, damit das Unternehmen mit der Anwendung von KI erfolgreich ist.

Mit Blick auf die strategische Ausrichtung des Unternehmens erarbeiten die Partner im ersten Schritt gemeinsam die Ziele einer sinnvollen Nutzung von KI-Systemen und Big-Data-Analysetools. Daraus ergeben sich Ideen für mögliche Anwendungsbereiche, beispielsweise für eine Optimierung von Produktionsprozessen, für eine vorausschauende Instandhaltung von Maschinenanlagen (Predictive Maintenance), für die Produktionsplanung, Logistik und Inventur oder für eine automatische Produktüberwachung.



Abbildung 3 Anwendungsgebiete von KI in der Produktion

Im zweiten Schritt werden die Ideen zu konkreten Anwendungsfällen ausgearbeitet, ihre Potenziale und Hindernisse in der Umsetzung und im Einsatz identifiziert und dabei die Perspektiven der verschiedenen Stakeholder des Unternehmens berücksichtigt.

Schließlich wird die Machbarkeit der untersuchten Anwendungsfälle bewertet. Dazu richtet das Projektteam seinen Fokus nicht nur auf die technische Umsetzung des KI-Systems, sondern wählt eine ganzheitliche Herangehensweise zur Implementierung. In die Betrachtung einbezogen werden neben der IT-Infrastruktur auch die verfügbaren Produktions- und Betriebsdaten, die strategische Relevanz des Vorhabens sowie die Organisationsstruktur des Unternehmens. Auf dieser Grundlage lassen sich Verbesserungspotenziale im Unternehmen selbst erkennen und Maßnahmen für eine erfolgreiche Einführung des KI-Systems in die praktische Anwendung ableiten.

### Erste Schritte: Frei zugängliche Datensätze für eigene KI-Projekte

Fehlende Erfahrung der Mitarbeitenden beim Umgang mit KI und ML führt dazu, dass trotz steigender Datenmengen eine enorme Anzahl an ML-Projekten scheitert. Die Ursache liegt unter anderem darin, dass die unternehmensinternen Daten unstrukturiert vorliegen, irrelevante Informationen enthalten oder nicht in ausreichender Menge gespeichert werden. In diesen Fällen ist es möglich, anhand frei verfügbarer Datensätzen erste Erfahrungen für den Einsatz von ML zu sammeln. Allerdings sind geeignete öffentlich zugängliche Datensätze mit Bezug zur Produktion auf unterschiedlichen Plattformen gespeichert.

Aus diesem Grund hat das Fraunhofer IPT öffentlich verfügbare Datensätze zusammengetragen und den wichtigsten Anwendungsfeldern der Produktion zugeordnet werden. Eine Gesamtübersicht kann unter <http://ipt.fraunhofer.de/ml-and-ai-in-production> heruntergeladen werden.

**Autoren** Jonathan Krauß | Jonas Dorißen

#### Das »AI Kick-Starter Bundle«

##### 1. Strategische Ziele des KI-Einsatzes

Identifizierung und Priorisierung strategischer Ziele von KI-Aktivitäten und Matching auf prototypische KI-Anwendungsfälle

##### 2. Use Case Design

Entwicklung ausgewählter KI-Anwendungsfälle in Bezug auf Stakeholder-Bedürfnisse und Potenziale

##### 3. AI Readiness Check

Bewertung der Machbarkeit einzelner KI-Anwendungsfälle, Gap-Analyse inkl. Lösungsvorschlägen und Mini-Roadmap



QR-Code zum Zugriff auf die Datensätze

# KI-Prozesse

## Datenvorverarbeitung sichert die Datenqualität

Derzeit werden vielfach Vorgehensweisen zur Datenvorverarbeitung entwickelt, die die Datenqualität verbessern. Automatisiertes Machine Learning (AutoML) setzt auf eine automatisierte Datenvorbereitung, die diese einfacher, intuitiver und schneller macht.

Quellen erhoben werden – von den Sensordaten einer Werkzeugmaschine über die Protokolle von Messgeräten bis hin zu manuellen Einträgen in Laborbüchern. Solche Rohdaten liegen zunächst nicht in einem direkt verwertbaren Zustand vor und können darüber hinaus Fehlstellen bei Sensorausfall oder falsche Angaben bei manuellen Einträgen aufweisen [14].

### Die Datenqualität bestimmt den Erfolg der Datenanalyse

Nur durch eine hohe Datenqualität lassen sich treffsicher statistische Datenanalysen durchführen, auf deren Grundlage maschinelles Lernen fußt (Abbildung 5). In produzierenden Unternehmen kann eine Vielzahl an Daten aus den unterschiedlichsten

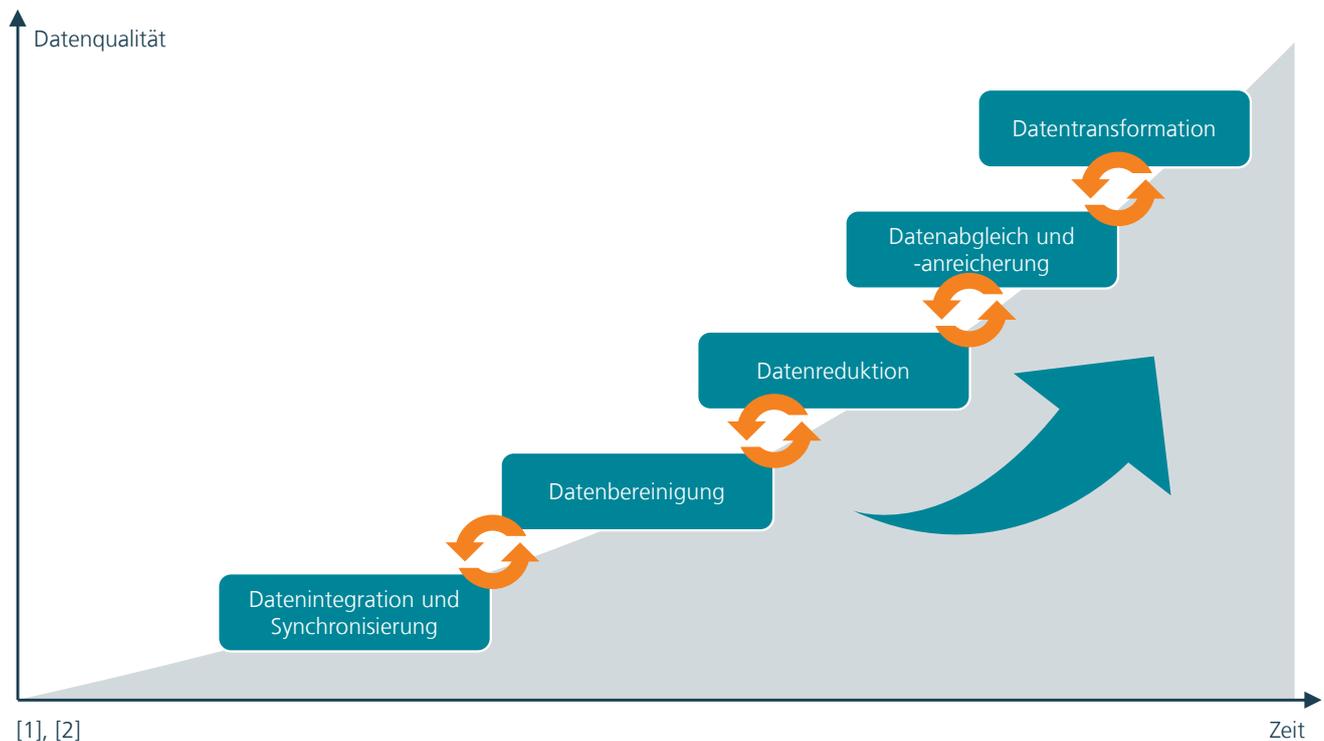


Abbildung 5: Ablauf der Datenvorbereitung in der Data-Preprocessing-Pipeline

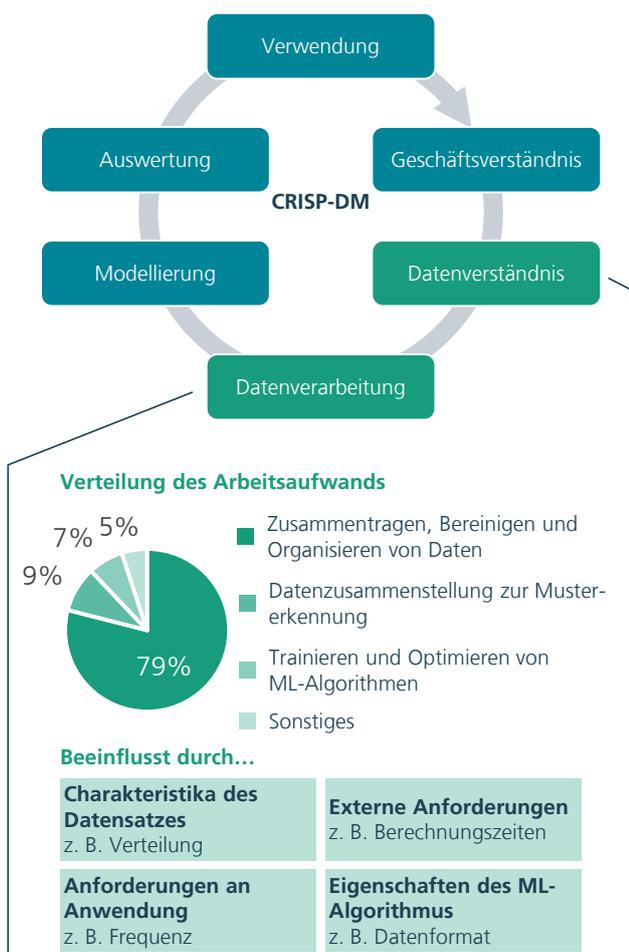
## Strukturierte Datensätze durch standardisiertes Data-Preprocessing

Um Daten in einen verwertbaren Zustand zu überführen und Datensätze von höchstmöglicher Qualität für nachfolgende Analysen bereitzustellen, hat das Fraunhofer IPT ein Vorgehen für ein standardisiertes Data Preprocessing entwickelt: Die sogenannte Data-Preprocessing-Pipeline stellt Methoden für eine strukturierte Vorverarbeitung der Daten in mehreren methodischen Schritten zur Verfügung (Abbildung 6):

- Integration (z. B. Verbinden und Trennen von Datensätzen)
- Bereinigung (z. B. Ermitteln von Ausreißern und offensichtlich falschen Datensätzen)
- Datenabgleich und Anreicherung (z. B. Interpolation zum Ergänzen fehlender Daten)
- Reduktion (z. B. Hauptkomponentenanalyse und Feature-Extraktion zur Annäherung umfangreicher Datensätze durch aussagekräftige Variablen)
- Transformation (z. B. One-Hot-Kodierung und Diskretisierung)

Als Ergebnis des Data-Preprocessing liegt dann ein aufbereiteter Datensatz vor, der für statistische Datenanalysen und Machine Learning genutzt werden kann. Im Zuge der Automatisierung des maschinellen Lernens wird besonders intensiv an der Automatisierung der Datenvorverarbeitung gearbeitet, da diese aufwändigen Prozesse die Grundvoraussetzung für weitere Analyseschritte bilden. Das Fraunhofer IPT untersucht den Einsatz der automatisierten Datenvorverarbeitung im Produktionskontext, um die bisherigen manuellen Tätigkeiten zu beschleunigen und die Data Scientists in den Unternehmen zukünftig von diesen monotonen Aufgaben zu entlasten.

**Autoren** Jonathan Krauß | Maik Frye



### Hauptkomponentenanalyse

Die Hauptkomponentenanalyse oder Principal Component Analysis (PCA) ist ein statistisches Verfahren zur Dekorrelation numerischer Vektoren. Ziel ist es, Datenpunkte in ein orthogonales Koordinatensystem zu transformieren, in dem keine Korrelation zwischen unterschiedlichen Dimensionen besteht.

Nun können Dimensionen mit niedriger Varianz unter geringem Informationsverlust entfernt werden – ein Grund, weshalb PCA oft zur Dimensionsreduktion genutzt wird. Letzteres dient im Allgemeinen dazu, Daten zu vereinfachen und zu komprimieren, um die Laufzeit nachgelagerter Algorithmen zu verringern.

### One-Hot-Kodierung

Die One-Hot-Kodierung dient der numerischen Kodierung symbolischer Werte. Hierbei wird jedem Symbol ein binärer Vektor zugewiesen. Die Länge des Vektors entspricht der Größe des Vokabulars, und jedem Symbol ist genau eine eigene Vektordimension zugeordnet. Für ein gegebenes Symbol erhält man die One-Hot-Kodierung, indem man die ihm zugewiesene Dimension auf 1 und alle übrigen auf 0 setzt.

[3], [4], [5]

Abbildung 6: Elemente der Datenqualität

# Datenbasierte Prozessoptimierung

ML-Modelle können eingesetzt werden, um teil- oder vollautonom Prozessketten zu planen und zu optimieren.

Neuentwicklungen und die Optimierung von Prozessen sollen dazu beitragen, Produktionssysteme immer besser auszulasten. Die voranschreitende Verfügbarkeit von Maschinen- und Prozessdaten im Zuge der Digitalisierung schafft nun neue Möglichkeiten, um Produktionssysteme weiter zu verbessern: Die wachsende Datengrundlage kann für den Einsatz von Machine Learning und Künstlicher Intelligenz zur Optimierung genutzt werden. [15]

Durch Machine Learning können KI-Systeme Produktqualität, Maschinenstillstände oder Prozesszustände voraussagen, sodass rechtzeitig und mit den richtigen Maßnahmen reagiert werden kann. Die Interpretation der Ergebnisse obliegt Data Scientists oder Prozessexperten. Interpretationsspielräume, inhärente Unsicherheiten der Modelle oder fehlendes Wissen über die korrekten Reaktionsschritte bergen in der konkreten Umsetzung noch große Herausforderungen. Der Einsatz voll- oder teilautonomer Systeme eröffnet Optimierungspotenziale in der Produktion: Selbst Unternehmen, denen Fachkräfte fehlen, könnten mithilfe von Machine-Learning-Modellen einzelne Prozesse oder Prozessketten optimieren.

## Die Zukunft der Prozessoptimierung

Das Fraunhofer IPT forscht an der Umsetzung voll- und teilautonomer Systeme für den Einsatz solcher Machine-Learning-Modelle in der Produktion (Abbildung 7). Multi-Agent-Systeme und serviceorientierte Architekturen ermöglichen die Integration von AutoML-Pipelines, die auch hier dabei helfen können, den Aufwand für den Anwender zu reduzieren. [16]

Durch den Einsatz sogenannter Optimierer können Prozessparameter auf Basis von Vorhersagen der Machine-Learning-Modelle angepasst werden, um eine optimale Qualität der Endprodukte zu erreichen und Produktionssysteme vollständig autonom zu regeln. [17] Dabei muss jedoch sichergestellt sein, dass das Ergebnis des Machine-Learning-Modells die Anlagen- und Arbeitersicherheit nicht gefährden kann. Die Modelle müssen außerdem so gut nachvollziehbar gestaltet sein, dass die Ergebnisse für Prozessexperten leicht zu interpretieren sind. Ein Ziel kann es sein, die Modelle und Anwendungen des Machine Learning zu zertifizieren, um sie für einen breit angelegten industriellen Einsatz verfügbar zu machen.

**Autoren** Jonathan Krauß | Hendrik Mende

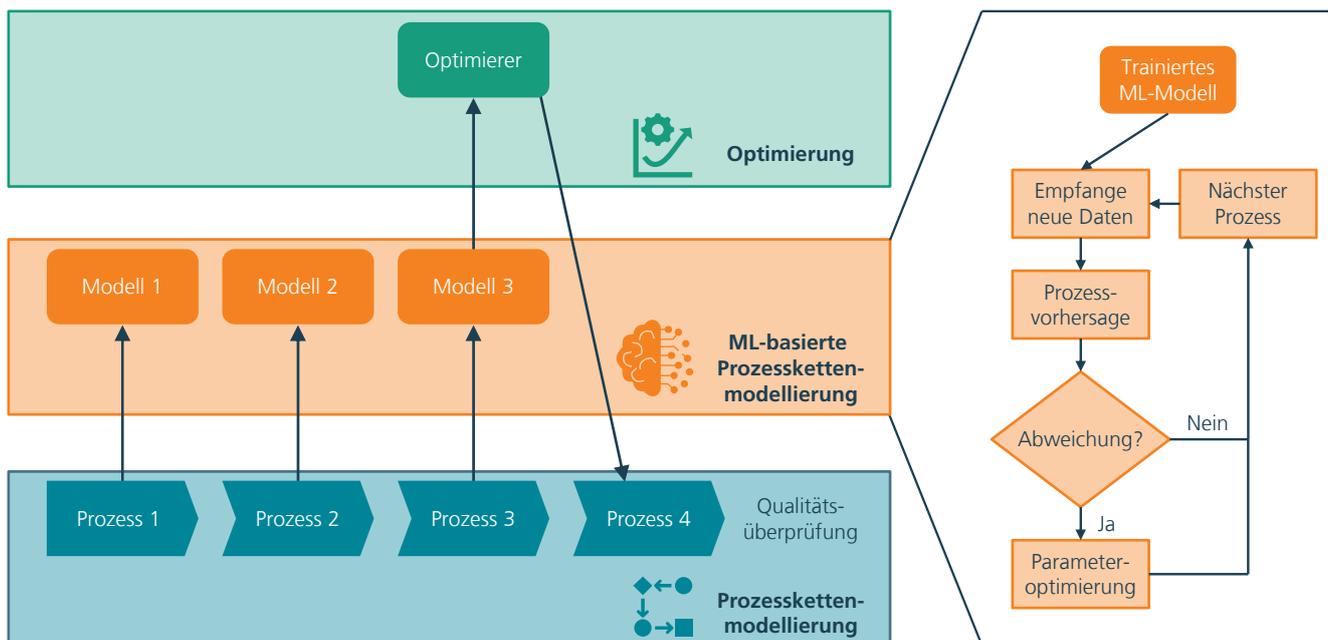


Abbildung 7: Datenbasierte Prozessoptimierung

## KI-gestützte Datenanalyse für eine automatisierte Planung

Konstruktionsdaten und darin enthaltene Metainformationen sind entscheidend für die Wahl von Prozessparametern in unterschiedlichen Fertigungssystemen. Eine KI-gestützte Klassifizierung von Bauteilen auf Basis existierender Daten der Fertigungshistorie kann wertvolle Unterstützung leisten.

Die regelbasierte Klassifizierung von Bauteilfeatures ist für simple Geometrielemente wie Bohrungen, Taschen oder Nuten in modernen CAM-Systemen bereits Stand der Technik. Sie wird für (semi-)automatisierte CAM-Planung verwendet und unterstützt CAM- und CAPP-Arbeitsprozesse.

Diese Art der Erkennung von Bauteilfeatures versagt jedoch bei der Klassifizierung komplexer 3D-Geometrien. Daher ist die Prozessplanung im Werkzeugbau für komplexe Bauteile heute eine manuelle Tätigkeit von Arbeitsvorbereitern oder CAM-Planern. Welche Fertigungsprozesse wie und in welcher Reihenfolge eingesetzt werden, um das Bauteil möglichst effizient in einer gegebenen Fertigungsumgebung zu fertigen, unterliegt dabei einem Entscheidungsprozess, der große Erfahrung auf Seiten des ausführenden Personals voraussetzt. Dies ist sowohl mit Blick auf bestehende Optimierungspotenziale als auch hinsichtlich des Risikos, dass entscheidende Personen im Betrieb ausfallen könnten, ein unbefriedigender Zustand.

Eine KI-gestützte 3D-Datenanalyse kann in dieser Situation helfen, die Qualität der Prozessplanung zu verstetigen sowie Fertigungsdaten als Wissensschatz anzusehen, zu sammeln und im Betrieb nutzbar zu machen.

Das Vorgehen ist dabei wie folgt: Zunächst werden die in den Fertigungsdaten hinterlegten Rohdaten der 3D-Geometrie in eine Vektormenge umgewandelt. Es folgt eine Analyse der Einfärbung der Oberflächen des 3D-Modells, wie sie zum Beispiel in Werkzeugbaubetrieben zur optischen Identifikation von Oberflächeneigenschaften oder zugeordneten Maßtoleranzen verwendet wird. Zuletzt werden dann noch Metainformationen wie Werkstoffeigenschaften hinzugefügt. So können für die manuelle oder semi-automatisierte Fertigungsplanung genutzte Einfärbungen des CAD-Modells weiterverwendet werden. Die aufbereiteten Daten werden anschließend mit den gewählten Prozessketten verknüpft, die durch historische Fertigungsdaten bereits bekannt sind. Durch die Verknüpfung lassen sich so Trainingsdaten für den Klassifizierungsalgorithmus der KI erzeugen. Dieser lernt dadurch, neue Werkstücke entsprechend der »Erfahrung« aus historisch durchlaufenen Prozessketten einzuordnen und neue Fertigungsprozessketten vorzuschlagen.

Das fertige Tool zur Featureerkennung dient schließlich zur Unterstützung des Prozessplaners und hilft langfristig dabei, die Prozessplanung zu automatisieren. Die Bauteilkomplexität ist in den gängigen Anwendungsfeldern häufig nicht sehr hoch, da Unternehmen in der Regel nur eine Teilmenge ihrer gefertigten Bauteile auf diesem Wege herstellen. Daher ist auch die Menge der Trainingsdaten eher gering. Gerade in der Einzel- und Kleinserienfertigung, wie sie in Werkzeugbaubetrieben überwiegend anzutreffen ist, bietet dieses Vorgehen ein großes Potenzial zur einheitlichen und automatisierten Verarbeitung von 3D-Daten.

**Autor** Grzegorz Stepień

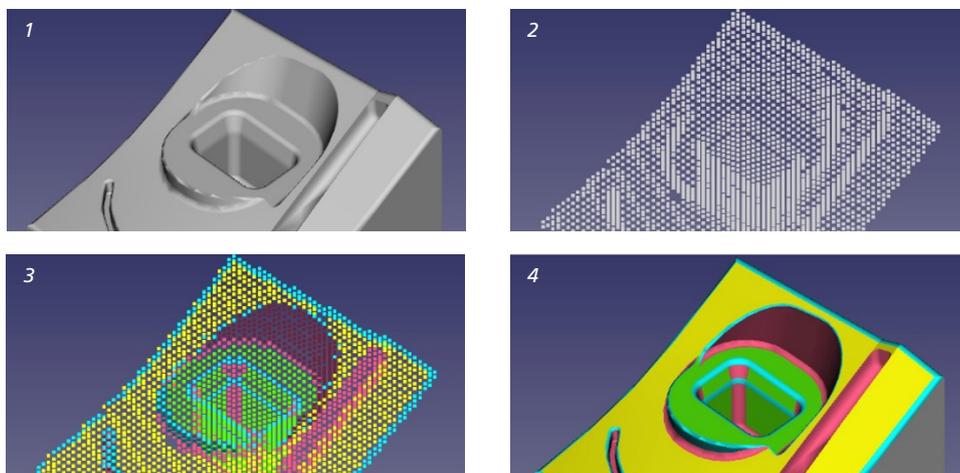


Abbildung 8: Schritte der 3D-Datenanalyse

## Zertifizierung KI-unterstützter Prozesse und Produkte

Die Zertifizierung KI-unterstützter Prozesse auf organisatorischer und technischer Ebene bildet eine zentrale Hürde beim Einsatz von KI in Unternehmen. Denn die entsprechenden Regularien dafür stehen noch nicht zur Verfügung. Dennoch besteht gerade in Unternehmen, die KI anwenden möchten, ein hoher Bedarf an Transparenz, Erklärbarkeit und Nachvollziehbarkeit der KI-Systeme.

Produzierende Unternehmen verbessern ihre Wettbewerbsfähigkeit in hohem Maße durch fehlerfreie und effiziente Produktionsprozesse. Hier ist es unverzichtbar, Anforderungen und Richtlinien genau zu erfüllen und dies sowohl zu garantieren, aber auch regelmäßig kontrollieren zu können. Den Nachweis kann eine Zertifizierung bescheinigen. Abhängig von Anwendungsfall und Branche werden unterschiedliche Anforderungen an eine Zertifizierung gestellt. In allen Fällen werden jedoch Transparenz, Erklärbarkeit und Nachvollziehbarkeit gefordert. Diese Anforderungen gelten nicht nur allgemein für Prozesse der industriellen Fertigung, sondern auch für KI-Systeme und alle Produkte und deren Fertigungsprozesse, bei denen KI-Lösungen eingesetzt werden.

Nur dann, wenn die für den jeweiligen Anwendungsfall vorliegenden Anforderungen erfüllt sind, werden die entsprechenden Produktionsprozesse von den Auditoren zertifiziert. Im Kontext der Produktion reicht die Performanz eines KI-Systems alleine nicht aus, vielmehr werden Transparenz, Erklärbarkeit und Nachvollziehbarkeit verlangt, um verstehen zu können, wie sich das KI-System etwa in sich ändernden Umgebungsbedingungen verhält. Gerade KI-Systeme, die in der Lage sind, komplexe Zusammenhänge abzubilden, sind häufig für den Menschen nicht mehr nachvollziehbar. Dabei kann eine entsprechende Interpretierbarkeit sowohl für Experten als auch für Endanwender von Interesse sein, um die wesentlichen Eigenschaften der KI-Anwendung und deren Funktionsweise zu verstehen und so auch Transparenz im Zertifizierungsprozess zu schaffen. Bei der Bild- und Textanalyse sind Methoden zur Verbesserung der Nachvollziehbarkeit bereits im Einsatz. Diese lassen sich jedoch nicht direkt auf Sensordaten in der Produktion übertragen.

Aus den Gründen mangelnder Transparenz, fehlender Nachvollziehbarkeit unzureichender Zertifizierbarkeit sind viele produzierende Unternehmen noch verunsichert, inwieweit KI überhaupt in der Einzel- und Kleinserienfertigung eingesetzt werden kann. 63 Prozent der produzierenden Unternehmen sehen laut Microsoft regulatorische Anforderungen als größtes Risiko und sehen deshalb vom Einsatz von KI-Systemen in der Produktion eher ab [18]. Da aktuelle Normen und Richtlinien die Anforderungen an KI-Systeme noch nicht aufgreifen, sollten diese zukünftig möglichst realistisch formuliert werden [19]. Parallel sollte jedoch schon jetzt daran gearbeitet werden, die Transparenz, Erklärbarkeit und Nachvollziehbarkeit der erfolgsversprechenden KI-Ansätze zu verbessern, damit die Zertifizierung schließlich auch erfolgen kann [20].



Abbildung 9: Zusammenhang von Interpretierbarkeit und Performanz [15]

Generell gibt es drei Möglichkeiten, ML-Verfahren nachvollziehbar, erklärbar und transparent zu gestalten:

- Interpretierbare Modelle: Um die Interpretierbarkeit zu verbessern, kann man sich auf interpretierbare Modellklassen beschränken, beispielsweise Entscheidungsbäume, regularisierte lineare Regression und Regel-Lerner.
- Nachgeschaltete Erklärung: Da die interpretierbaren Modelle für viele Lernaufgaben keine ausreichende Genauigkeit erreichen, ist es ein aktuelles Forschungsziel, auch Erklärungen für Black-Box-Modelle zu finden.
- Während die beiden ersten Möglichkeiten unabhängig vom zugrundeliegenden Modell sind, gibt es auch modellbezogene Ansätze, um nicht interpretierbare, tiefe künstliche neuronale Netze erklärbar zu machen.

Im Rahmen ihrer Zusammenarbeit in der Fraunhofer-Allianz Big Data und Künstliche Intelligenz entwickeln das Fraunhofer IPT und das Fraunhofer-Institut für Intelligente Analyse- und Informationssysteme IAIS entsprechende Techniken weiter, so zum Beispiel Ansätze wie Explainable AI [21] oder Informed Machine Learning [22].

## Wege zur Zertifizierung von KI-Systemen

Es gibt bis heute noch keine festgelegten Vorgehensweisen für die Zertifizierung KI-gestützter Produktionsprozesse. Sowohl für die KI als auch für die Produktion gibt es verschiedene Möglichkeiten der Zertifizierung. Diese bestehenden Richtlinien bieten bereits erste Grundlagen für eine Zertifizierung von KI im Produktionsumfeld. Diese sollten bei der Entwicklung neuer, passender Zertifizierungsansätze nicht außer Acht gelassen werden. Als Grundlage für eine erfolgreiche Zertifizierung KI-gestützter Produktionsprozesse können bestehende Richtlinien aus fünf verschiedenen Bereichen herangezogen werden:

Der erste Bereich setzt sich aus Normen, Richtlinien und Vorschriften zusammen, die im Produktionsumfeld ohne explizite Berücksichtigung der KI angewendet werden. Im zweiten Bereich werden Zertifizierungen aus der Informatik betrachtet, jedoch ohne Berücksichtigung von KI. Im dritten Bereich wird die KI explizit thematisiert, jedoch zunächst ohne Fokus auf einzelne Fachbereiche. Im vierten Bereich sind Zertifizierungsansätze aus produktionsfremden Bereichen von Relevanz und im fünften Bereich schließlich Zertifizierungen für die Produktion.

**Autoren** Jonathan Krauß, Tobias Claus Brandstätter

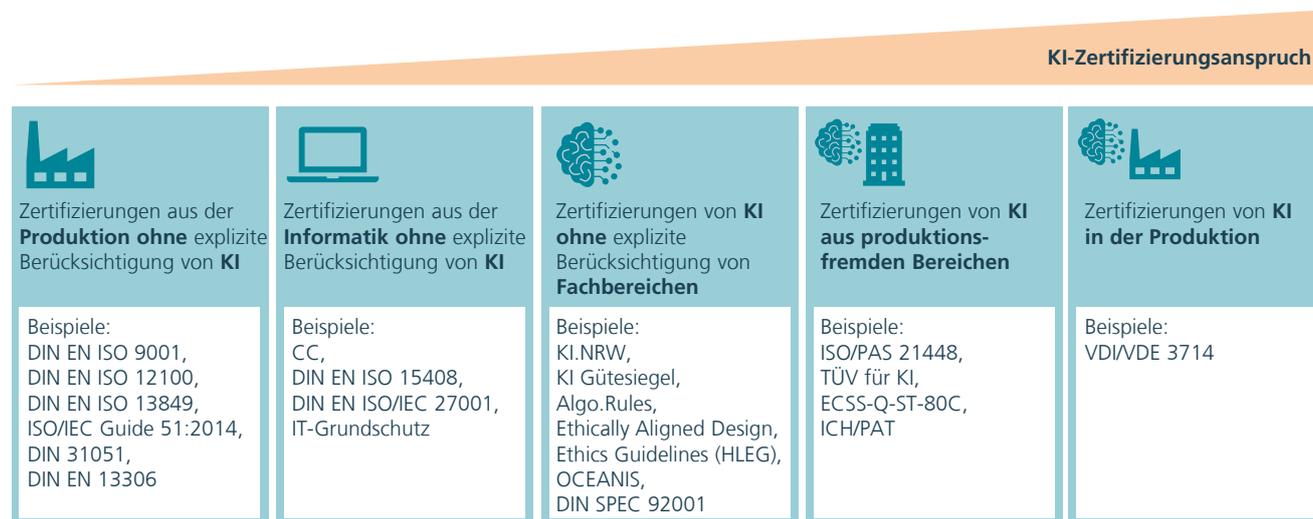


Abbildung 10: Stand der Zertifizierbarkeit

# Beispiele aus der Anwendung

## Werkzeugverschleiß durch Körperschall erkennen

Die Herstellung qualitativ hochwertiger Produkte verlangt eine effiziente Überwachung von Maschinenzustand und Prozessstabilität. Durch eine KI-gestützte Analyse von Sensordaten lässt sich Werkzeugverschleiß rechtzeitig erkennen, sodass Werkzeuge optimal genutzt und Produktausschuss reduziert werden können.

Autor Zhen Zhen

Zur Fertigung anspruchsvoller Bauteile sind produzierende Unternehmen nach wie vor auf umfangreiches Wissen und Erfahrung angewiesen: So können routinierte Maschinenbediener beispielsweise das Ende der Standzeit von Fräswerkzeugen anhand der Geräusche und Vibrationen am Werkstück bestimmen oder den Verschleiß einer Werkzeugschneide beim Diamantdrehen unter dem Mikroskop erkennen.

Einen neuen Weg zur Online-Überwachung von Werkzeugen in der Präzisions- und Ultrapräzisionsbearbeitung geht das Fraunhofer IPT mit dem Einsatz von Körperschallsensoren. Ein besonderer Vorteil für die Prozessüberwachung ist der sehr einfache Messaufbau bei gleichzeitig hoher Messempefindlichkeit. Da das Körperschallsignal jedoch viele Einflussfaktoren und Prozessgrößen zusammengefasst abbildet, lassen sich konkrete Informationen über den Verschleiß von Werkzeugen nicht einfach anhand definierter Schwellwerte oder Hüllkurven auf Basis des Rohsignals gewinnen. Eine KI-gestützte Analyse hilft in dieser Situation, das Körperschallsignal so zu modellieren, dass wertvolle Information erkennbar werden.

In der Datenvorverarbeitung wird das Körperschallsignal vom Zeitbereich (zeitabhängige Darstellung von Signalen) in den Frequenzbereich (frequenzabhängige Darstellung) transformiert, gefiltert, in Sequenzen zerlegt und zu Verschleißwerten zugeordnet. Damit werden Trainingsdaten für einen Deep-Learning-Algorithmus erzeugt. Neuronale Netze werden mit diesen Trainingsdaten trainiert, sodass ein Modell zur Erkennung des Werkzeugverschleißes angelernt werden kann. Das angelernte Modell kann nun in ein Assistenzsystem integriert werden, dem Maschinenbediener in Echtzeit Rückmeldung zum augenblicklichen Verschleißzustand des Werkzeugs geben und sogar den Zeitpunkt des Austauschs empfehlen.

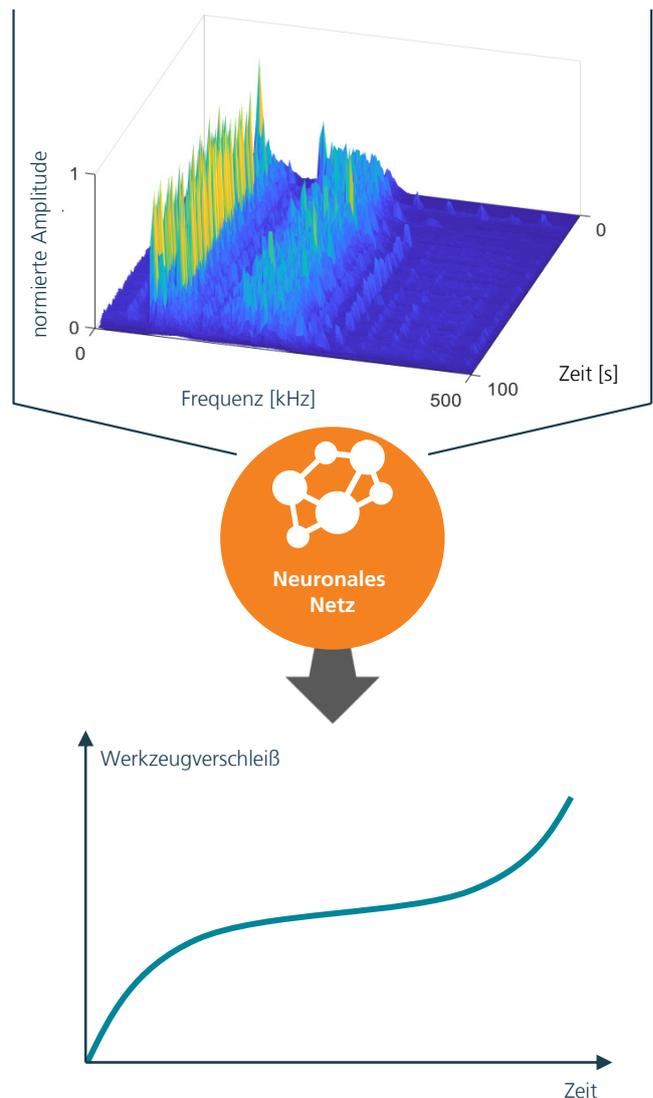


Abbildung 11: Körperschallspektrum als Input für Neuronales Netz, Werkzeugverschleiß als »Output«

# Deep Learning zur optischen Erkennung von Werkzeugverschleiß

Hartmetallwerkzeuge bestehen zu rund zehn Prozent aus Kobalt, einem begehrten Rohstoff, der aufgrund seiner Eignung für den Einsatz in der Elektromobilität in Zukunft einem starken Preisanstieg unterworfen sein könnte. Für produzierende Unternehmen, die spanende Prozesse einsetzen, wird es sich damit mehr denn je lohnen, Werkzeuge mit Kobaltanteilen effizienter als bisher zu nutzen.

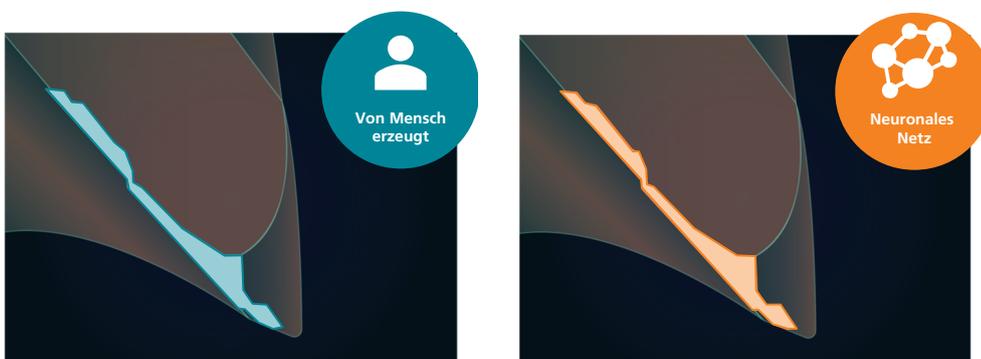
Werkzeugverschleiß ist bereits heute ein Kostentreiber im produzierenden Gewerbe [28]: Neben den Kosten für die Werkzeuge entstehen weitere Aufwände: Anlagenstillstände für Werkzeugwechsel, Nachbearbeitung beschädigter Oberflächen, Ausschussteile oder im schlimmsten Fall Schäden an der Werkzeugmaschine selbst. Verschlissene Werkzeuge werden daher nach dem Erreichen eines definierten Verschleißzustandes ausgetauscht.

In der Praxis wird der Verschleißzustand eines Werkzeuges nicht einheitlich nach festgeschriebenen Regeln bewertet [23]. Wegen der fehlenden Standardisierung sind die Fertigungsprozesse nicht exakt reproduzierbar – weder an verschiedenen Werkstandorten noch innerhalb eines einzelnen Betriebs. Ungenutztes Potenzial verschwindet in Recyclingtonnen, wenn nur kleine Bereiche der Schneide genutzt werden oder Werkzeuge zu früh aussortiert werden. Viele Werkzeuge können mit fortgeschrittener Standzeit zwar nicht mehr zum Schlichten von Oberflächen, aber durchaus noch zum Vorschlichten oder Schruppen eingesetzt werden. Jedes Zerspanwerkzeug optimal einzusetzen und maximal auszunutzen sollte die Devise sein.

Um den Werkzeugverschleiß objektiv zu erkennen und zu bewerten eignet sich ein Deep-Learning-Ansatz zur Bildanalyse: Dabei wird ein tiefes, neuronales Netz trainiert, anhand von Datensätzen mikroskopischer Aufnahmen verschiedener Zerspanwerkzeuge den Werkzeugverschleiß zu erkennen. Gelingt es dem neuronalen Netz, verschlissene Flächen auf unbekanntem Testbildern zu erkennen, die es zuvor nicht gesehen hat, beweist dies die Robustheit des Netzes [25]. Abbildung 12 veranschaulicht diese Leistung anhand eines dem Netz unbekanntem Werkzeugs. Links ist eine Maske zu sehen, die durch einen Menschen erzeugt wurde und rechts eine durch das neuronale Netz detektierte Fläche. Der Dice-Koeffizient gibt an, mit welcher Genauigkeit die Vorhersage im Vergleich zur Maske bewertet werden kann. Dabei wäre der maximale Wert von 1 eine hundertprozentige Übereinstimmung zwischen Maske und Vorhersage. Ein Dice-Koeffizient ab 0,5 gilt als gute Vorhersage, da zuverlässige Aussagen über den Werkzeugverschleiß möglich sind. Der Vorhersagewert im Beispiel in Abbildung 12 lag bereits bei mehr als 0,6, für den gesamten Testdatensatz sogar bei 0,7.

Für die Automatisierung der Produktion kann der Einsatz solcher Deep-Learning-Modelle erhebliche Effizienzsteigerungen bewirken. Denn ohne eine verlässliche Erkennung und Bewertung des Werkzeugverschleißes kommt die zunehmende Automatisierung der spanenden Fertigung nicht aus. Der Einsatz intelligenter Algorithmen und Modelle kann Assistenzsysteme hervorbringen, die zum Beispiel anhand mobiler Endgeräte Informationen aus der Maschine an den Operator weitergeben und ihn in seinen Entscheidungen beraten oder anleiten. Zudem kann der Betrieb von Maschinen beispielsweise personallos erweitert werden. Die automatisierte Erkennung, Messung und Klassifizierung von Schneidwerkzeugverschleiß unter Verwendung

maschinenintegrierter Mikroskope im Zusammenspiel mit Algorithmen der Künstlichen Intelligenz und klassischen Bildverarbeitungsmethoden kann hier einen Weg für die weitere Automatisierung der Produktion im Sinne der Industrie 4.0 ebnen.



**Autor** Carsten Holst

Abbildung 12: Schematisierte Darstellung einer Fräswerkzeugschneide, menschengemachte Verschleißmaske und Vorhersage des neuronalen Netzes

## Das CAM-System der Zukunft

Mit der Zunahme an komplexen Bauteilen wächst auch die Relevanz der simultanen 5-Achs-Fräsbearbeitung [23], und der weltweite Wettbewerb zwingt viele Unternehmen, ihre Fertigung so weit wie möglich zu automatisieren. Zusammengenommen führt das dazu, dass die manuelle Werkzeugbahn-Programmierung schon bald vollständig durch automatisiert arbeitende CAM-Systeme abgelöst werden muss.

Für die Bahnplanung eines 5-Achs-Fräsprozesses muss aus verschiedenen Strategien wie High-Feed, dynamischem oder konventionellem Fräsen eine passende ausgewählt werden. Dabei verlangt jede Strategie nach der Angabe verschiedener Parameter wie Bahnabstand, Bahntoleranz oder Aufmaß. Unter der Berücksichtigung von Zeit, Kosten und Qualität muss dann eine optimale Strategie und Parameterbelegung gewählt werden, um das Werkstück kosteneffizient zu fertigen.

Die erste Parametrierung der Bahnstrategie ergibt sich aus der Erfahrung des jeweiligen CAM-Programmierers. Dieser setzt eine initiale Lösung für eine Parametermenge nach eigenem Ermessen (Abbildung 13). Für jede Parameterbelegung versucht das CAM-Programm eine passende Werkzeugbahn zu berechnen. Wenn dies nicht gelingt, muss der CAM-Programmierer die Parameterbelegung solange anpassen, bis die Berechnung gelingt. Die erste Bewertung der berechneten Werkzeugbahn erfolgt durch den CAM-Programmierer selbst. Dieser achtet dabei vor allem auf Stetigkeit und Diskontinuitäten der Werkzeugbahn. Im zweiten Schritt wird mit einer Materialabtragssimulation geprüft, ob nach Ausführung der Operation noch ungewünschtes Restmaterial stehen bleibt. Die Bahnberechnung wird anschließend für angepasste Parameterbelegungen solange wiederholt, bis eine zufriedenstellende Werkzeugbahn errechnet wurde.

Zur Ergänzung der Beurteilung können Simulationen der Werkzeugbahn dienen: Das Fraunhofer IPT entwickelt Simulationen, die die Kräfte, die Temperaturen und den Werkzeugverschleiß während des Herstellungsprozesses vorhersagen und anschließend eine Aussage über die Bauteilqualität treffen können. Diese Simulationen sollen zukünftig als weitere Bewertungsgröße in die CAM-Bahnplanung eingehen und für die Anpassung des Werkzeugpfads, etwa zur Kompensation von Werkzeugverschleiß und Bauteilabdrängung, genutzt werden.

Das CAM-System der Zukunft wird durch selbständige Optimierung der Parameter effizienter und verbessern durch Simulationen die Bauteilqualität. Die Bahnplanung soll zukünftig nur einmal von einem CAM-Programmierer gestartet werden, indem er eine initiale Parameterbelegung auswählt. Die Berechnung der Werkzeugbahnen und der Simulationen sowie das Bewerten und anschließende Neusetzen der Parameter werden selbstständig vom CAM-Programm ausgeführt. Zu diesem Zweck kommen evolutionäre Algorithmen und Cloud-Computing zum Einsatz (Abbildung 14).

Evolutionäre Algorithmen zählen zu den Optimierungsverfahren und sind inspiriert von der Evolutionstheorie: Im Sinne des »Survival of the Fittest« werden Mitglieder einer Population eliminiert, die sich am schlechtesten behaupten. Durch Rekombination und Mutation der besseren Mitglieder wird die Population immer wieder neu aufgebaut. Übersetzt in die Sprache eines CAM-Programmierers bedeutet das: Das automatisierte Programm berechnet verschiedene Parametrierungen und Bearbeitungsstrategien und bewertet diese anhand verschiedener Kenngrößen. Nur die am besten bewertete Strategie wird dem CAM-Programmierer als Ergebnis der Bahnberechnung übermittelt. Dadurch lassen sich iterative und zeitaufwändige Optimierungsvorgänge vermeiden, die der CAM-Programmierer sonst manuell durchführen muss.

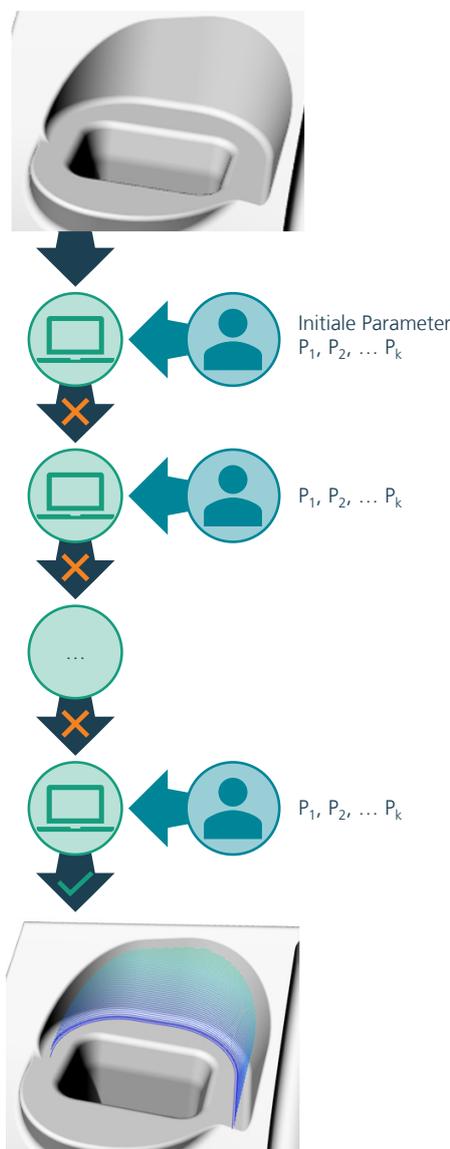


Abbildung 13: Erfahrungs-basierte Parametrierung des CAM-Programms

Jede Werkzeugbahn gilt dabei als ein Mitglied der Population. Zunächst wird aus der initialen Parameterbelegung des CAM-Programmierers die erste Werkzeugbahn errechnet. Durch automatische Erzeugung neuer Werkzeugbahnen mit leicht geänderten Parametern wächst so eine größere Population an Werkzeugbahnen. Die Software bewertet dann Werkzeugbahnen mithilfe der Simulationen und einem »Key Performance Indicator« (KPI). Dieser KPI drückt die Güte einer Werkzeugbahn aus: je höher der Wert, desto besser. Werkzeugbahnen mit einem kleinen KPI werden aus der Population entfernt. Die übrigen Werkzeugbahnen bilden die Grundlage einer neuen Population. Dies wiederholt sich solange, bis eine Werkzeugbahn mit einem KPI in vorher definierter Höhe entstanden ist.

Setzt ein erfahrener CAM-Programmierer die Ausgangsdaten fest, ist meist schon die erste Generation der Werkzeugbahnen nah an einer optimalen Lösung. Daher lässt sich die Erfahrung gut nutzen, während der Computer im Anschluss die repetitive und zeitaufwändige Aufgabe des iterativen Anpassens der Parameter übernimmt.

Um sicherzustellen, dass eine optimale Werkzeugbahn innerhalb weniger Minuten errechnet werden kann, finden Berechnungen in einem Cloud-Computing-System statt. Dadurch, dass jede Werkzeugbahn unabhängig von den anderen ist, können die Berechnungen der Simulationen parallel ablaufen.

Ein Cloud-Computing-System mit einer größeren Anzahl an CPU-Kernen beschleunigt die Überprüfung der gesamten Population mithilfe von Simulationen. Durch die Rechenkraft des Cloud-Systems lassen sich auch rechenaufwändigere Simulationen durchführen. So können die Werkzeugbahnen anhand von Werkstückeigenschaften und Verschleiß aussortiert werden und es ergibt sich eine Werkzeugbahn, mit der ein Werkstück noch präziser und effizienter hergestellt werden kann.

Auch mit viel Erfahrung nimmt der Prozess der Bahnplanung heute noch viel Zeit in Anspruch. Dies liegt in erster Linie an der Menge der einstellbaren Parameter. Da das CAM-Programm die Optimierung der verschiedenen Parameterbelegungen durch Berechnungen übernimmt, kann hier viel Zeit eingespart werden. Die hohe Rechenleistung von Cloud-Computern und die Anwendung moderner evolutionärer Algorithmen trägt dazu bei, Fertigungsprozesse stärker zu automatisieren und die 5-Achs-Fräsbearbeitung auch für spontane kurzlebige Werkstückanforderungen kostengünstiger einzusetzen.

**Autor** Sven Schiller

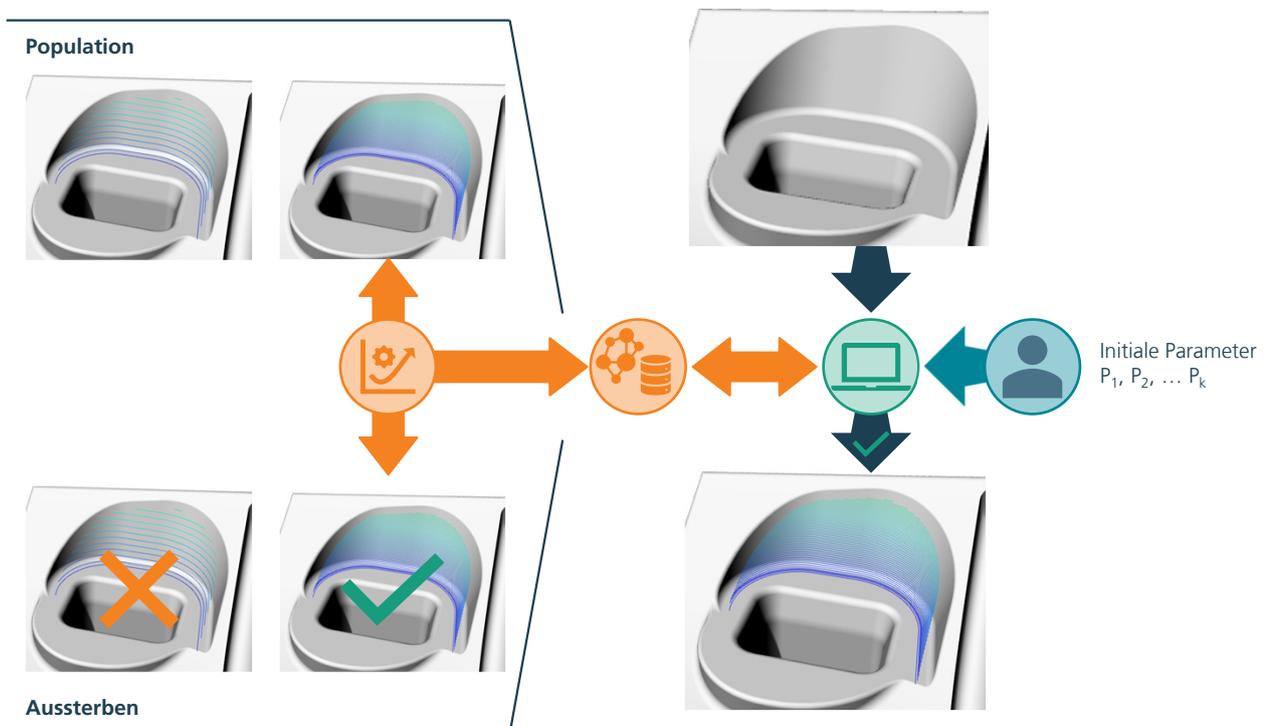


Abbildung 14:  
Lösungsansatz zur automatisierten CAM-Programmierung

# Qualitätsvorhersage in der Produktion

Machine-Learning-Algorithmen und -Systeme können die Vorhersage der Produktqualität unterstützen: Ob ein Produkt den Spezifikationen entspricht, kann in der Produktion bisher erst nach Abschluss aller dazugehörigen Fertigungsprozesse festgestellt werden. Bestünde die Möglichkeit, genau vorherzusagen, wann ein Produkt außerhalb der Spezifikationen liegt, könnten Maschinen mit anderen Produkten belegt werden. Dies würde die Effizienz der gesamten Prozesskette deutlich verbessern.

Unternehmen haben das Ziel, effiziente Prozessketten zu gestalten. Im Folgenden ist eine beispielhafte Prozesskette aus sechs verschiedenen Prozessschritten aufgeführt, die optimiert werden soll. Jedes Bauteil oder Produkt durchläuft jeden Prozessschritt nacheinander, wobei einige Prozesse Stunden oder sogar Tage dauern. Die Prozesskette ist in Abbildung 15 dargestellt.

Ob ein Produkt innerhalb oder außerhalb der Spezifikationen ist, wird nach Abschluss jedes Prozesses durch ein Qualitätssicherungs-Gate (QG) bestimmt. Da die Zykluszeit der gesamten Prozesskette mehrere Tage dauert, wäre es sinnvoll, vorherzusagen, ob ein Produkt bereits in früheren Phasen die Spezifikation nicht mehr erfüllt. Eine genaue Vorhersage würde die Anpassung der Maschinenbelastung ermöglichen. Dies führt zu einer höheren Effizienz und Flexibilität der gesamten Prozesskette.

Folgend auf das Quality Gate nach Prozess 5 können drei Klassen erreicht werden: Das Produkt wird in Ordnung sein, das Produkt wird in Prozess 6 aufgrund von Fehler A ausfallen; oder das Produkt wird in Prozess 6 aufgrund von Fehler B ausfallen. Das Verhältnis des Auftretens zwischen den drei Klassen beträgt in diesem Beispiel 158:3:1, wobei die Hauptklasse aus den Produkten besteht, die keine Fehler aufweisen. Entlang der Prozesskette müssen dazu mehrere Messungen für eine Vielzahl an Produkten durchgeführt werden. Dies führt zu einem Rohdatensatz mit einigen 10 000 Spalten, obwohl viele davon oft irrelevante Daten enthalten, wie beispielsweise obere und untere Toleranzen einer bestimmten Messung.

Zur Lösung dieser Aufgabe werden Data Scientists mit Erfahrung in der Anwendung von ML in der Produktion sowie den entsprechenden Prozessexperten eingesetzt.

Die Datenintegration ist oft komplex, da häufig nur unstrukturierte Daten erfasst werden können oder vorliegen. Zudem muss regelmäßig eine Zusammenführung mehrerer Datenquellen aus den verschiedenen Prozessen erfolgen, um die Instanzen in tabellarischer Form zu strukturieren. Entsprechend liegt bei der Datenvorverarbeitung der Schwerpunkt auf der Ausbalancierung eines Datensatzes, der Interpolation fehlender Werte und des Kodierens kategorischer Merkmale. Außerdem werden bei hohen Anzahlen an Datenquellen Dimensionsreduktionen durchgeführt.

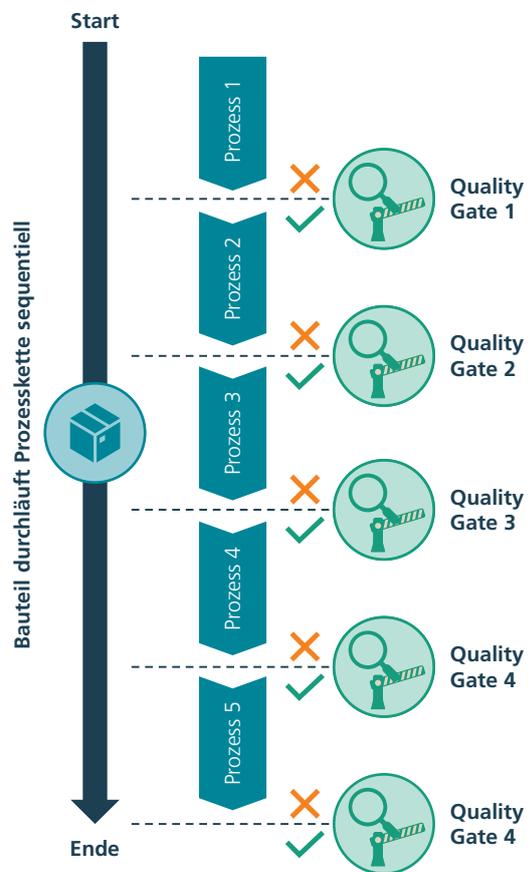


Abbildung 15: Veranschaulichung der Prozesskette aus dem Anwendungsfall [24]

Für die Auswahl der vielversprechendsten ML-Algorithmen und Hyperparameter-Tuning-Techniken kann eine am Fraunhofer IPT entwickelte Logik für die Produktion angewendet werden. Basierend auf dieser Logik werden dann Optimierungsmethoden und Lernmodelle implementiert [27]. Um resultierende Modelle weiter zu verbessern, werden weitere Parameter, wie die Entscheidung, Data Imputation (Vervollständigen von Datensätzen) oder Scaling durchzuführen, eingebunden.

Das finale Modell kann dann auf einem Webserver bereitgestellt werden, über dessen Oberfläche neue Produktdaten eingegeben und die entsprechenden Vorhersagen getroffen werden können (Abbildung 16).

Die Erfahrung aus Industrieprojekten zeigt, dass die folgenden drei Stakeholder besonderen Einfluss auf den Projekterfolg haben:

- 1) Manager
- 2) Projektleiter
- 3) Data Scientist

Aus Sicht des Managers ist es wichtig von Beginn an realistisch einschätzen zu können, ob die Datengrundlage für den Anwendungsfall ausreicht. Das größte Hindernis bei ML-Projekten ist eine fehlende oder unzureichende Datengrundlage. Des Weiteren ist von zentraler Bedeutung, eine realistische Erwartungshaltung bezüglich der zu erwartenden Ergebnisse zu haben. Aus Sicht des Projektleiters ist es wichtig, die strategische Einordnung des Projekts zu kennen: Soll der Produktionsprozess nachhaltig verbessert werden oder steht eine öffentliche Wirksamkeit im Vordergrund? Für den Projekterfolg ist es weiterhin von großer Relevanz, sowohl Expertise aus dem Bereich Data Science als auch Prozess im Team zu haben. Für die Arbeit des Data Scientists bieten vor allem »Jupyter Notebooks«, eine Plattform für die Darstellung von Software-Projekten, eine effiziente Möglichkeit, die Ergebnisse an die Projektleitung zu kommunizieren. Bei der Auswahl der ML-Algorithmen reicht es in den meisten Fällen aus, die Algorithmen einzusetzen, zu denen bereits Erfahrungswerte vorliegen. Der Einsatz von Automated Machine Learning bietet die Möglichkeit, manuelle Schritte zu automatisieren.

**Autor** Jonathan Krauß



Abbildung 16: Anwendungsoberfläche

# Zusammenfassung

---

**Die Einzel- und Kleinserienfertigung erfordert anforderungsgerechte Lösungen für die Produktion, da Lern- und Skaleneffekte nicht vorhanden sind. Aufgrund gesteigerter Rechenleistung sind Systeme mit Künstlicher Intelligenz heute in der Lage, selbstständig Entscheidungen zu treffen und Maßnahmen umzusetzen. Unternehmen in der Einzel- und Kleinserienfertigung werden so befähigt, mittels Künstlicher Intelligenz effizientere und leistungsfähigere Prozesse zu etablieren.**

In diesem Whitepaper wird der Begriff der Künstlichen Intelligenz definiert und es werden Potenziale für die Einzel- und Kleinserienfertigung aufgezeigt. Besonders das Automated Machine Learning ermöglicht es, manuelle und arbeitsintensive Modellier- und Analysetätigkeiten automatisiert auszuführen. Dadurch ist eine einfache Anwendung von Machine Learning ohne besondere Fachkenntnisse möglich. Grundsätzlich sind die Anwendungsgebiete für Machine Learning und Künstliche Intelligenz in der Produktion sehr vielfältig. Sie müssen daher stets auf ihre strategische, wirtschaftliche, technologische und organisatorische Eignung überprüft werden.

Hinsichtlich des KI-Prozesses ist die Vorgehensweise zur Nutzung von Künstlicher Intelligenz, wie die Sicherstellung einer ausreichenden Datenqualität durch standardisierte und automatisierte Vorgehensweisen zur Datenvorverarbeitung zu betrachten: Die Data-Preprocessing-Pipeline erlaubt in mehreren Schritten eine strukturierte Vorverarbeitung der Daten, sodass dann ein aufbereiteter Datensatz zur Verfügung steht. Auf Basis dieser Datensätze können zum Beispiel ML-Modelle zur Planung und Optimierung von Prozessketten eingesetzt werden. Durch Analyse und Abgleich mit den Konstruktionsdaten der Fertigungshistorie können so Bauteile anhand einer Feature-Erkennung klassifiziert und Prozessparameter optimiert werden. Schwierig ist jedoch, dass bis heute noch keine festgelegte Vorgehensweise zur Zertifizierung existiert. Demnach bildet die Zertifizierung KI-unterstützter Prozesse eine entscheidende Hürde für einen umfassenden Einsatz Künstlicher Intelligenz. Transparenz, Erklärbarkeit und Nachvollziehbarkeit der KI-Ansätze müssen deshalb auch zukünftig im Fokus stehen.

Die Anwendungsfälle von Künstlicher Intelligenz im Werkzeugbau sind zahlreich. So kann beispielsweise der Verschleiß von Fräswerkzeugen automatisiert überwacht werden. Ein Körperschallsensor akquiriert Daten, die durch KI-gestützte Analyse ausgewertet werden, um Erkenntnisse über den Verschleiß des Werkzeugs zu gewinnen. Des Weiteren können zur Detektion von Werkzeugverschleiß Deep-Learning-Methoden in Kombination mit optischer Messtechnik eingesetzt werden. Anhand der Analyse mikroskopischer Aufnahmen verschiedener Fräswerkzeuge können automatisiert Verschleißmasken detektiert werden und die Produktivität durch einen zielgerichteten Einsatz des Fräswerkzeugzeugs gesteigert werden. Auch in CAM-Programmen finden KI-Ansätze vielfältige Anwendungsmöglichkeiten. Bei komplexen Bauteilgeometrien führt eine automatisierte Programmierung zu einer höheren Effizienz gegenüber der herkömmlichen manuellen Werkzeugbahnprogrammierung. Effizienzsteigerungen lassen sich auch in der Qualitätsvorhersage von Produkten durch ML-Algorithmen erzielen.

Diese Beispiele geben nur einen kleinen Einblick in die vielfältigen Anwendungsgebiete von Künstlicher Intelligenz in der Einzel- und Kleinserienfertigung. Durch immer leistungsfähigere Algorithmen und KI-Prozesse lassen sich in Zukunft noch weitere, völlig neue Anwendungsfelder erschließen. Um diese gezielt und anforderungsgerecht in der Praxis zu etablieren und weiterzuentwickeln, sind Softwareanbieter, Unternehmen und Forschungseinrichtungen gleichermaßen gefordert, gemeinsam neue Lösungen zu entwickeln und umzusetzen.

**Autor** Rainer Horstkotte

# Glossar

---

**Machine Learning** versetzt Systeme in die Lage, automatisiert aus Erfahrungen zu lernen. Aus vorhandenen Daten werden mittels Algorithmen Muster und Gesetzmäßigkeiten erkannt und Lösungen abgeleitet.

Das **Data Preprocessing** umfasst die Vorbereitung der Daten, um deren nachgelagerte Analyse zu vereinfachen. Hier werden die Daten von fehlerhaften oder fehlenden Werten gesäubert, in eine einheitliche Struktur integriert und die für das Analyseziel relevanten Werte (Features) extrahiert.

Der **Data Scientist** oder Datenwissenschaftler ist dafür zuständig, eine vorhandene Datenbasis in einem interdisziplinären Wissenschafts- und Industrieumfeld zu analysieren und Wissen abzuleiten.

**Data Mining** ist das Verarbeiten großer Datenbestände unter systematischer Anwendung statistischer Methoden, um Muster zu identifizieren und Korrelationen zu finden.

**Cloud Computing** beschreibt die Bereitstellung von verteilter IT-Infrastruktur und IT-Leistungen in Form von Servern, Datenspeichern oder darauf ausgeführten Applikationen als Dienstleistung über das Internet.

Unter **Population** werden in der biowissenschaftlichen Evolutionstheorie Individuen von genetischer Verbundenheit bezeichnet. In der Statistik wird damit die Menge aller Objekte bezeichnet, über die eine Aussage getroffen werden soll.

Als **Deployment** bezeichnet man den Prozess der Softwareinstallation in einer bestehenden Produktionsumgebung. Dies kann sich auf die Installation gänzlich neuer Software beziehen, auf Softwareupdates oder auf die Integration neuer Softwarefeatures in den Produktionsablauf.

Als **Deep Learning** bezeichnet man das Training »tiefer« neuronaler Netze, also solcher mit vielen Zwischenschichten. Diese Netze können aufgrund ihrer mehrschichtigen Struktur komplexe Daten verarbeiten, verlangen jedoch aufgrund der Vielzahl der Parameter große Mengen an Trainingsdaten.

**Diskretisierung** bezeichnet die (typischerweise verlustbehaftete) Abbildung eines kontinuierlichen numerischen Wertebereichs auf den nächstgelegenen Wert aus einer diskreten numerischen Menge. Die Voxelisierung von 3D-Modellen ist ein konkretes Beispiel, bei dem Diskretisierung zum Einsatz kommt.

Künstliche **neuronale Netze** sind eine Klasse mathematischer Modelle aus dem Bereich des Machine Learning, deren Struktur von biologischen Neuronen und Synapsen inspiriert sind.

**Big Data** bezeichnet umfangreiche Datenmengen, die groß, schnelllebig, komplex und oft schwach strukturiert sind. Sie stellen deshalb besondere Anforderungen an Algorithmen und Software, um effizient verarbeitet werden zu können.

**Dice-Koeffizient** oder **Jaccard Index** ist ein Ähnlichkeitsmaß zwischen zwei Mengen endlicher Größe. Definiert ist es als Quotient der Größe der Schnittmenge zweier Mengen und der Größe ihrer Vereinigung. Einsatz findet es beispielsweise beim Training von Objektdetektoren, um eine detektierte Menge an Pixeln mit der Menge der tatsächlich zum Objekt gehörenden Pixeln zu vergleichen.

**Data Imputation** ist der Prozess der Vervollständigung fehlender Daten durch substituierte Werte. Hierfür existiert eine Vielzahl an statistischen Verfahren.

Als **Feature Scaling** bezeichnet man die Normalisierung des Datenwertebereichs. Häufig angewendete Verfahren sind Standardisierung (auch Z-Normalisierung genannt), Min-Max-Normalisierung und die Einheitsvektor-Normalisierung. Aus numerischen Gründen liefern Machine Learning Verfahren oft bessere Ergebnisse, wenn Datendimensionen zuvor normalisiert wurden. Daher ist die Normalisierung ein wichtiger Schritt beim Data Preprocessing.

# Referenzen

---

- [1] Russell, S. J.; Norvig, P. (1995): Artificial intelligence. A modern approach. Upper Saddle River: Prentice Hall.
- [2] Seifert, I.; Bürger, M.; Wangler, L.; Christmann-Budian, S.; Rohde, M.; Gabriel, P.; Zinke, G. (2018): Potenziale der Künstlichen Intelligenz im produzierenden Gewerbe in Deutschland. Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie zum Technologieprogramm PAiCE – Platforms | Additive Manufacturing | Imaging | Communication | Engineering. Berlin: iit-Institut für Innovation und Technik in der VDI/VDE Innovation + Technik GmbH. Online verfügbar: [https://www.bmwi.de/Redaktion/DE/Publikationen/Studien/potenziale-kuenstlichen-intelligenz-im-produzierenden-gewerbe-in-deutschland.pdf?\\_\\_blob=publicationFile&v=8](https://www.bmwi.de/Redaktion/DE/Publikationen/Studien/potenziale-kuenstlichen-intelligenz-im-produzierenden-gewerbe-in-deutschland.pdf?__blob=publicationFile&v=8) (Zuletzt aufgerufen: 11.10.2021).
- [3] Bauer, H.; Richter, G.; Wüllenweber, J.; Beunig, M.; Wee, D.; Klein, H. (2017): Smartening up with Artificial Intelligence (AI) – What’s in it for Germany and its Industrial Sector? New York: McKinsey & Company, Inc. Online verfügbar: <https://www.mckinsey.com/~media/mckinsey/industries/semiconductors/our%20insights/smartening%20up%20with%20artificial%20intelligence/smartening-up-with-artificial-intelligence.ashx> (Zuletzt aufgerufen: 11.10.2021).
- [4] Böttcher, B.; Velten, C.; Schwalm, A.-L. (2018): Machine Learning in deutschen Unternehmen. Kassel: Crisp Research AG.
- [5] McCauley, D.; Ross, C. (2016): Artificial Intelligence in the real world. The business case takes shape. London: The Economist Intelligence Unit Limited. Online verfügbar: [https://impact.economist.com/perspectives/sites/default/files/Artificial\\_intelligence\\_in\\_the\\_real\\_world\\_0.pdf](https://impact.economist.com/perspectives/sites/default/files/Artificial_intelligence_in_the_real_world_0.pdf) (Zuletzt aufgerufen: 11.10.2021).
- [6] Stachowiak, H. (1973): Allgemeine Modelltheorie. Wien: Springer.
- [7] Hutter, F.; Kotthoff, L.; Vanschoren, J. (Hrsg.) (2019): Automated Machine Learning. Cham: Springer International Publishing. DOI: <https://doi.org/10.1007/978-3-030-05318-5>.
- [8] Das, S.; Cakmak, U. M. (2018): Hands-on automated machine learning. A beginner’s guide to building automated machine learning systems using AutoML and Python. Birmingham: Packt Publishing.
- [9] Lenzerini, M. (2002): Data Integration: A Theoretical Perspective. In: Abiteboul, S.; Kolaitis, P.G.; Popa, L. (Hrsg.): PODS ’02: Proceedings of the twenty-first ACM SIGMOD-SIGACT-SIGART symposium on Principles of database systems. New York: ACM Press. S. 233–246. DOI: <https://doi.org/10.1145/543613.543644>.
- [10] Cognilytica Research (2019): Data Engineering, Preparation, and Labeling for AI 2019: Getting Data Ready for Use in AI and Machine Learning Projects.
- [11] Han, J.; Kamber, M.; Pei, J. (2012): Data mining: Concepts and techniques. Third Edition. Amsterdam: Elsevier/Morgan Kaufmann.
- [12] Kotthoff, L.; Thornton, C.; Hoos, H. H.; Hutter, F.; Leyton-Brown, K. (2019): Auto-WEKA: Automatic Model Selection and Hyperparameter Optimization in WEKA. In: Hutter, F.; Kotthoff, L.; Vanschoren, J. (Hrsg.): Automated Machine Learning. Methods, Systems, Challenges. Cham: Springer Publishing. S. 81–95. DOI: [https://doi.org/10.1007/978-3-030-05318-5\\_4](https://doi.org/10.1007/978-3-030-05318-5_4).
- [13] Langley, P. (2002): Lessons for the computational discovery of scientific knowledge. In: Proceedings of First International Workshop on Data Mining Lessons Learned. Sydney: University of New South Wales. S. 9–12.
- [14] Sessions, V.; Valtorta, M. (2006): The Effects of Data Quality on Machine Learning Algorithms. In: Talbur, J. R.; Pierce, E. M.; Wu, N.; Traci, C. (Hrsg.): Proceedings of the 11th International Conference on Information Quality, MIT, Cambridge, MA, USA, November 10-12, 2006. S. 485–498.
- [15] Krauß, J.; Dorißen, J.; Mende, H.; Frye, M.; Schmitt, R. H. (2019) Machine Learning and Artificial Intelligence in Production: Application Areas and Publicly Available Data Sets. In: Wulfsberg, J. P.; Hintze, W.; Behrens, B.-A. (Hrsg.): Production at the leading edge of technology. Proceedings of the 9th Congress of the German Academic Association for Production Technology (WGP), September 30th - October 2nd, Hamburg 2019. Berlin, Heidelberg: Springer. S. 493–501. DOI: [https://doi.org/10.1007/978-3-662-60417-5\\_49](https://doi.org/10.1007/978-3-662-60417-5_49).
- [16] Vogel, P.-A.; Vu, A.-T.; Mende, H.; Grunwald, T.; Bergs, T.; Schmitt, R. H. (2019): Approaches and methodologies for process development of thin glass forming. In: Unger, B. L.; DeGroote Nelson, J. (Hrsg.) Optifab 2019. Bellingham: SPIE. DOI: <https://doi.org/10.1117/12.2536431>.
- [17] Krauß, J.; Frye, M.; Döhler Beck, G. T. Schmitt, R. H. (2019): Selection and Application of Machine Learning-Algorithms in Production Quality. In: Beyerer, J.; Kühnert, C.; Niggemann, O. (Hrsg.): Machine Learning for Cyber Physical Systems. Selected papers from the International Conference ML4CPS 2018. Berlin, Heidelberg: Springer. S. 46–57. DOI: [https://doi.org/10.1007/978-3-662-58485-9\\_6](https://doi.org/10.1007/978-3-662-58485-9_6).
- [18] Bendiek, S. (2019): Artificial Intelligence in Europe – Germany, Outlook for 2019 and Beyond. Online verfügbar: <https://cloudblogs.microsoft.com/industry-blog/de-de/>

government/2019/05/17/artificial-intelligence-in-europe-germany-outlook-for-2019-and-beyond/ (Zuletzt aufgerufen: 03.09.2019).

- [19] DIN e.V. (2019): Künstliche Intelligenz. Mit Normung und Standardisierung innovationsfreundliche Rahmenbedingungen für die Technologie der Zukunft schaffen. Online verfügbar: <https://www.din.de/blob/300540/ee6c35719f2172d1cc000552b1a6bcf2/19-01-din-positionspapier-kuenstliche-intelligenz-data.pdf> (Zuletzt aufgerufen: 29.05.2021).
- [20] Grupp, M.; Bues, M.-M. (2018): Künstliche Intelligenz. Situation und Maßnahmenkatalog. Online verfügbar: <https://ki-verband.de/wp-content/uploads/2018/06/KI-Verband-Positionspapier-25062018.pdf> (Zuletzt aufgerufen: 29.05.2019).
- [21] Fraunhofer Institute for Telecommunications, Heinrich Hertz Institute, HHI (2019): Interpretable Machine Learning. Online verfügbar: <https://www.hhi.fraunhofer.de/en/departments/vca/research-groups/machine-learning/research-topics/interpretable-machine-learning.html> (Zuletzt aufgerufen: 11.10.2021).
- [22] Fraunhofer Cluster of Excellence Cognitive Internet Technologies (2019): Forschungszentrum Maschinelles Lernen. Online verfügbar: <https://www.cit.fraunhofer.de/de/zentren/maschinelles-lernen.html> (Zuletzt aufgerufen: 11.10.2021).
- [23] IndustryARC (2019): Cutting Tools Market - Forecast (2020 – 2026): Analysis.Research.consulting. Online verfügbar: <https://www.industryarc.com/Report/16304/cutting-tools-market.html> (Zuletzt aufgerufen: 08.10.2021).
- [24] Ivester, R. W.; Kennedy, M.; Davies, M.; Stevenson, R.; Thiele, J.; Furness, R.; Athavale, S. (2000): ASSESSMENT OF MACHINING MODELS: PROGRESS REPORT. In: *Machining Science and Technology* 4 (3), S. 511–538. DOI: <https://doi.org/10.1080/10940340008945720>.
- [25] Bergs, T.; Holst, C.; Gupta, P.; Augspurger, T. (2020): Digital image processing with deep learning for automated cutting tool wear detection. In: *Procedia Manufacturing* 48, S. 947-958. DOI: <https://doi.org/10.1016/j.promfg.2020.05.134>.
- [26] Werkzeugbau-Datenbank des Fraunhofer IPT und des WZL der RWTH Aachen
- [27] Falkner, S.; Klein, A.; Hutter, F. (2018): BOHB: Robust and Efficient Hyperparameter Optimization at Scale. In: Dy, J.; Krause, A. (Hrsg.): *Proceedings of the 35th International Conference on Machine Learning*. Stockholm: PMLR. S. 1437–1446. Online verfügbar: <http://proceedings.mlr.press/v80/falkner18a/falkner18a.pdf> (Zuletzt aufgerufen: 11.10.2021).

## Autoren

---

Kristian Arntz, Tobias Claus Brandstätter,  
Jonas Dorißen, Maik Frye, Jonathan Krauß,  
Leonie Krebs, Carsten Holst,  
Rainer Horstkotte, Hendrik Mende,  
Sven Schiller, Grzegorz Stepień,  
Moritz Wollbrink, Zhen Zhen

## Kontakt

---

Rainer Horstkotte  
Geschäftsfeldleiter Werkzeugbau  
Telefon +49 241 8904-243  
[rainer.horstkotte@ipt.fraunhofer.de](mailto:rainer.horstkotte@ipt.fraunhofer.de)

Fraunhofer IPT  
Steinbachstr. 17  
52074 Aachen  
[www.ipt.fraunhofer.de](http://www.ipt.fraunhofer.de)

DOI: 10.24406/ipt-n-640931