

VDI

Zentrum
Ressourceneffizienz

Im Auftrag des:



Bundesministerium
für Umwelt, Naturschutz
und nukleare Sicherheit

Potenziale der schwachen künstlichen Intelligenz für die betriebliche Ressourceneffizienz



Studie: Potenziale der schwachen künstlichen Intelligenz für die betriebliche Ressourceneffizienz

Autorinnen und Autoren:

Deloitte Consulting GmbH - Analytics & Cognitiv:

Dr.-Ing. Robert Friedrich, Florian Ploner, Christian Thomas Schäfer, Tim Disselhoff, Andreas Petkau, Constantin Hennemann, Jakob Moecke, Tobias Wätzig, Oliver Zimmert

Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA:

Lara Waltersmann, Steffen Kiemel, Dr.-Ing. Robert Miehe, Prof. Dr.-Ing. Alexander Sauer

Fachliche Ansprechpartner VDI Zentrum Ressourceneffizienz GmbH:

Dr.-Ing. Jan Philipp Menn, Dr.-Ing. Christof Oberender, Dr. Martin Vogt

Wir danken Herrn Prof. Dr.-Ing. Jens Lambrecht, Fachgebiet Industry Grade Networks and Clouds an der Technischen Universität Berlin, für seine fachliche Unterstützung.

Die Studie wurde im Auftrag des Bundesministeriums für Umwelt, Naturschutz und nukleare Sicherheit erstellt.

Redaktion:

VDI Zentrum Ressourceneffizienz GmbH (VDI ZRE)

Bülowstraße 78

10783 Berlin

Tel. +49 (0)30 2759506-0

zre-info@vdi.de

www.ressource-deutschland.de

Titelbild: © VDI ZRE/Julia Zschiedrich

Gedruckt auf umweltfreundlichem Recyclingpapier.

VDI ZRE Publikationen:
Studien

Potenziale der schwachen künstlichen
Intelligenz für die betriebliche
Ressourceneffizienz

INHALTSVERZEICHNIS

ABBILDUNGSVERZEICHNIS	6
TABELLENVERZEICHNIS	8
ABKÜRZUNGSVERZEICHNIS	11
KURZFASSUNG	13
EXECUTIVE SUMMARY	14
1 EINLEITUNG	15
1.1 Motivation	15
1.1.1 Ressourceneffizienz in der betrieblichen Praxis	16
1.1.2 Das KI-Ökosystem in Deutschland	20
1.2 Zielsetzungen	24
1.3 Methodisches Vorgehen	26
2 GRUNDLAGEN UND BEGRIFFE	27
2.1 Schwache künstliche Intelligenz	27
2.1.1 Überwachtes Lernen (Supervised Learning)	29
2.1.2 Unüberwachtes Lernen (Unsupervised Learning)	30
2.1.3 Verstärkendes Lernen (Reinforcement Learning)	31
2.2 Ressourcen und Ressourceneffizienz	32
2.3 Typische Anwendungsszenarien	34
3 EXPERTENBEFRAGUNG	40
3.1 Methode	40
3.2 Charakterisierung der Umfrageteilnehmenden	42
3.3 Ergebnisse der Expertenbefragung	44
3.4 Fazit	58
4 METHODIK ZUR POTENZIALANALYSE VON ANWENDUNGSSZENARIEN DER KI	60
4.1 Klassifikation von Anwendungsszenarien	60
4.1.1 KI-Methoden	61
4.1.2 Eingliederung entlang der Wertschöpfungskette	61

4.1.3	Umsetzungsaufwand	62
4.1.4	Kennzahlenmodell zur Messung der Ressourceneffizienz	64
4.2	Reifegradmodell für Unternehmen	66
5	POTENZIALANALYSE AUSGEWÄHLTER ANWENDUNGSSZENARIEN	69
5.1	AS 1: Vorausschauende Wartung	71
5.1.1	Vorausschauende Wartung von Fräsen durch die Analyse akustischer Frequenzspektren	71
5.1.2	Praxisbeispiel AS 1: LUIS Technology GmbH, LUVIS AI GmbH & Stadtreinigung Hamburg AöR	74
5.2	AS 2: Optimierung der Prozesskette	78
5.2.1	Energieeinsparung im Fertigungsprozess in der Wafer- Produktion	78
5.2.2	Praxisbeispiel AS 2: Gestalt Robotics GmbH	81
5.3	AS 3: Optische Fehlererkennung	84
5.3.1	Echtzeitanalyse von Bildmaterial zur Fehlererkennung in der Faserspritzgussfertigung	85
5.3.2	Exkurs: Werner-von-Siemens Centre for Industry and Science	88
5.4	AS 4: Fehlervorhersage (Predictive Quality)	91
5.4.1	Fehlervorhersage bei der Umformung von Blechzuschnitten zu Karosserieteilen	91
5.4.2	Praxisbeispiel AS 4: atlan-tec Systems GmbH	94
5.5	AS 5: Planung der Prozesskette	97
5.5.1	Simulation und Modellierung von Betriebszuständen in der Mikrofertigung	97
5.5.2	Praxisbeispiel AS 5: Julius Zorn GmbH	101
5.6	AS 6: Produktoptimierung	105
5.6.1	Methodik zur datengetriebenen Produktgenerierung und Retrofit-Planung	105
5.6.2	Praxisbeispiel AS 6: IANUS Simulation GmbH und M+S Silicon GmbH & Co. KG	111
5.7	AS 7: Autonome Transportsysteme	115
5.7.1	Automatisierung der Produktionslinien durch fahrerlose Transportsysteme	115
5.7.2	Praxisbeispiel AS 7: Blechwarenfabrik Limburg GmbH	119
5.8	AS 8: Sustainability Analytics	122

5.8.1	CO ₂ -relevante Optimierung mittels maschinellen Lernens und Cloud-Technologie	122
5.8.2	Praxisbeispiel AS 8: juS.TECH AG	129
5.8.3	Praxisbeispiel AS 8: GEDIA Automotive Gruppe	132
6	HEMMNISSE UND ERFOLGSFAKTOREN FÜR DIE ANWENDUNG VON KI	136
6.1	Hemmnisse	136
6.2	Erfolgsfaktoren	143
7	HANDLUNGSFELDER FÜR KMU, POLITIK UND WISSENSCHAFT	148
7.1	Handlungsfelder für KMU	149
7.1.1	Daten- und KI-Strategie	149
7.1.2	Machbarkeits- und Potenzialanalysen	151
7.1.3	Implementierung und Skalierung	152
7.2	Handlungsfelder für die Politik	154
7.2.1	Anreize und Motivation zur Ressourceneffizienz	154
7.2.2	KI-Forschungsförderung	155
7.2.3	Datenschutz, Datennutzung und Datenzugang	157
7.3	Handlungsempfehlungen für die Wissenschaft	159
7.3.1	Beratungs-, Schulungs- und Informationsangebote für Unternehmen	160
7.3.2	Vertrauen von Unternehmen und Gesellschaft in KI-Anwendungen	162
7.3.3	Forschung zu KI und Ressourceneffizienz	163
8	ZUSAMMENFASSUNG UND FAZIT	165
	LITERATURVERZEICHNIS	169
	ANHANG A: ÜBERSICHT IN DER PRAXIS GÄNGIGER KI-METHODEN	179
	ANHANG B: HYPOTHESEN DER EXPERTENBEFRAGUNG	181
	ANHANG C: DIMENSIONEN DES REIFEGRADMODELLS	182

ABBILDUNGSVERZEICHNIS

Abbildung 1: KI-Wachstumszahlen 2020 für das Bundesland Hamburg	23
Abbildung 2: Charakterisierung der teilnehmenden Unternehmen	42
Abbildung 3: Unternehmensbranchen und Unternehmensbereiche	44
Abbildung 4: Einsatz und Bedeutung von KI	46
Abbildung 5: Unternehmens- und Anwendungsbereiche, in denen KI eingesetzt wird	48
Abbildung 6: Motivation für den Einsatz bereits implementierter und geplanter KI	49
Abbildung 7: Einschätzung zur Verbesserung der Ressourceneffizienz durch KI	50
Abbildung 8: Vergleich der erwarteten Einsparung von Ressourcen gegenüber der tatsächlichen Einsparung	52
Abbildung 9: Heranziehen externer Partner bei der Entwicklung von KI	54
Abbildung 10: Gegenüberstellung von KMU und Großunternehmen bezogen auf den (zukünftigen) Einsatz von KI	57
Abbildung 11: Dimensionen zur Klassifikation und Bewertung von Praxisanwendungen	60
Abbildung 12: Abgrenzung von Primär- und unterstützenden Aktivitäten der Wertschöpfungskette	62
Abbildung 13: Dimensionen des Reifegradmodells	67
Abbildung 14: Gehäuseaufbau mit Board, MEMS-Sensor, GPS- und 4G-Antenne	76
Abbildung 15: User-Interface für die zielgerichtete Line Clearance auf einem Tablet anhand des digitalen Zwillings der Produktionsumgebung	83
Abbildung 16: Digitaler Zwilling für eine Outdoor-Logistikumgebung	84

Abbildung 17: Initialer Produktionsprozess von Kunststoffrohren	95
Abbildung 18: Produktionsprozess von Kunststoffrohren unter Miteinbeziehung eines trainierten neuronalen Netzes	96
Abbildung 19: Austritt eines Profils aus dem Extrusionswerkzeug & Visualisierung der inhomogenen Geschwindigkeitsverteilung am Austritt	112
Abbildung 20: FTS bei der Bereitstellung von Rohmaterial und Fertigware	121
Abbildung 21: Interne und externe Einflussfaktoren auf nachhaltige Wertschöpfungsketten sowie deren Potenziale	123
Abbildung 22: Facetten eines CO ₂ -Flottenoptimierungsszenarios	124
Abbildung 23: Anwendung von KI entlang einer Sustainability Analytics Lösung	125
Abbildung 24: Hemmnisse für den Einsatz von KI	137
Abbildung 25: Identifizierte Hemmnisse für die Einführung von KI	139
Abbildung 26: Identifizierte Erfolgsfaktoren für die Einführung von KI	143
Abbildung 27: Übersicht identifizierter Handlungsfelder	149

TABELLENVERZEICHNIS

Tabelle 1:	Ausgewählte Hypothesen je Kategorie	41
Tabelle 2:	Bewertungskriterien für die Umsetzung mit entsprechender Abstufung von geringem, mittlerem und hohem Aufwand	63
Tabelle 3:	Kennzahlensystem zur Messung der Ressourceneffizienz	66
Tabelle 4:	Qualitative Bewertungskriterien für die Steigerung der Ressourceneffizienz	70
Tabelle 5:	Übersicht der Anwendungsszenarien und Praxisbeispiele	71
Tabelle 6:	Technologische Umsetzung von AS 1	72
Tabelle 7:	Aufwandseinschätzung für AS 1	73
Tabelle 8:	Qualitative Potenzialabschätzung von AS 1 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell	74
Tabelle 9:	Technologische Umsetzung von AS 2	79
Tabelle 10:	Aufwandseinschätzung für AS 2	80
Tabelle 11:	Qualitative Potenzialabschätzung von AS 2 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodells	81
Tabelle 12:	Technologische Umsetzung von AS 3	86
Tabelle 13:	Aufwandseinschätzung für AS 3	87
Tabelle 14:	Qualitative Potenzialabschätzung von AS 3 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell	88
Tabelle 15:	Technologische Umsetzung von AS 4	92
Tabelle 16:	Aufwandseinschätzung für AS 4	93

Tabelle 17:	Qualitative Potenzialabschätzung von AS 4 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell	94
Tabelle 18:	Technologische Umsetzung von AS 4	99
Tabelle 19:	Aufwandseinschätzung für AS 4	100
Tabelle 20:	Qualitative Potenzialabschätzung von AS 4 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell	101
Tabelle 21:	Schritte und Hilfsmittel zur Optimierung der Lagerhaltung und Produktionsplanung	103
Tabelle 22:	Technologische Umsetzung von AS 6	107
Tabelle 23:	Aufwandseinschätzung für AS 6	108
Tabelle 24:	Qualitative Potenzialabschätzung von AS 6 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell	110
Tabelle 25:	Technologische Umsetzung von AS 7	117
Tabelle 26:	Aufwandseinschätzung für AS 7	118
Tabelle 27:	Qualitative Potenzialabschätzung von AS 7 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell	119
Tabelle 28:	Technologische Umsetzung von AS 8	126
Tabelle 29:	Aufwandseinschätzung für AS 8	127
Tabelle 30:	Auswirkungen auf die Ressourceneffizienz von AS 8 anhand des Kennzahlenmodells	128
Tabelle 31:	Beschreibung von technologischen, ökologischen, ökonomischen und sozialen Hemmnissen für den Einsatz von KI	140
Tabelle 32:	Beschreibung von technologischen, strategischen, sozialen und regulatorischen Erfolgsfaktoren für den Einsatz von KI	144

Tabelle 33:	Zusammenstellung von in der Praxis etablierten Aufgabengebieten der künstlichen Intelligenz mit einer Auswahl an KI-Methoden	179
Tabelle 34:	Übersicht der aufgestellten Hypothesen	181
Tabelle 35:	Ausprägungen des Reifegradmodells: KI-Strategie	182
Tabelle 36:	Ausprägungen des Reifegradmodells: Menschen	183
Tabelle 37:	Ausprägungen des Reifegradmodells: Prozesse	183
Tabelle 38:	Ausprägungen des Reifegradmodells: Daten	184
Tabelle 39:	Ausprägungen des Reifegradmodells: Technologien und Plattformen	185

ABKÜRZUNGSVERZEICHNIS

AI	Artificial Intelligence
API	Application Programming Interface (Anwendungsschnittstelle)
ARIMA	Autoregressive Integrated Moving Average (autoregressives integriertes gleitendes Durchschnittsmodell)
AS	Anwendungsszenario
BERT	Bidirectional Encoder Representations from Transformers (bidirektionale Encoder-Darstellungen von Transformatoren)
BMU	Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit
CFD	Computational Fluid Dynamics (numerische Strömungsmechanik)
CO₂	Kohlenstoffdioxid
CNN	Convolutional Neural Network (gefaltetes neuronales Netzwerk)
DQN	Deep Q-Network (tiefes Q-Netzwerk)
DDQN	Dueling Deep Q-Network (duellierendes tiefes Q-Netzwerk)
DSGVO	Datenschutz-Grundverordnung
EDSA	Europäischer Datenschutzausschuss
dpi	Dots per Inch (Punkte pro Zoll; Merkmal der Bildauflösung)
F&E	Forschung und Entwicklung
FFT	Fast Fourier Transform (schnelle Fourier-Transformation)

FPP	Forecasting: Principles and Practice (Vorhersage: Grundlagen und Praxis)
FTS	Fahrerloses Transportsystem
GPS	Global Positioning System (Globales Positionsbestimmungssystem)
HDPE	High Density Polyethylen (Hart-Polyethylen)
KI	Künstliche Intelligenz
KMU	Kleine und mittlere Unternehmen
KPI	Key Performance Indicator (Leistungskennzahl)
LSTM	Long Short-Term Memory (langes Kurzzeitgedächtnis)
MEMS	Micro Electro Mechanical System (Mikro-Elektronisch-Mechanische Systeme)
ML	Maschinelles Lernen
MVP	Minimum Viable Product (minimal brauchbares oder existenzfähiges Produkt)
RF	Random Forest Algorithm (Zufallswald)
RNN	Recurrent Neural Network (rückgekoppeltes neuronales Netz)
ROI	Return on Investment (Kapitalrendite)
SME	Small and Medium-sized Enterprises
SVM	Support Vector Machine (Stützvektormaschine)
THG	Treibhausgas
VDE	Verband der Elektrotechnik Elektronik Informations- technik e. V.
VDI	Verein Deutscher Ingenieure e.V.
VDI ZRE	VDI Zentrum Ressourceneffizienz GmbH

KURZFASSUNG

In der Gesellschaft nehmen Fragestellungen zu Ressourceneffizienz und nachhaltiger Produktion einen immer höheren Stellenwert ein, wodurch sich auch Unternehmen stärker mit der Thematik befassen. Durch den Einsatz künstlicher Intelligenz (KI) konnten verschiedene Maßnahmen in Unternehmen realisiert werden, um Kosten einzusparen, Qualität zu verbessern und Wettbewerbsvorteil zu erlangen. Diese Erfolge sind nur in geringem Maße auf die betriebliche Ressourceneffizienz übertragen worden. Die damit verbundenen Potenziale wurden zwar grundsätzlich erkannt, jedoch nur unzureichend qualifiziert und quantifiziert. Die qualitative Lücke adressiert die vorliegende Studie „Potenziale der schwachen künstlichen Intelligenz für die betriebliche Ressourceneffizienz“, indem sie auf effizienten Einsatz von Material, Energie und Wasser sowie die Reduktion entstehender Treibhausgasemissionen abzielt. Quantitative Aussagen sind aufgrund unzureichender Datenlage schwierig. KI und Ressourceneffizienz werden integrativ betrachtet und in Zusammenhang mit der betrieblichen Praxis gebracht. Die Studie basiert auf einer methodischen Literaturrecherche, einer Befragung von kleinen und mittleren Unternehmen (KMU) und größeren Firmen sowie auf Gesprächen mit Expertinnen und Experten. Hauptzielgruppe der Studie sind KMU. Für sie werden Potenziale zur Steigerung der Ressourceneffizienz aufgezeigt und Anreize für den Einsatz von KI geschaffen. In diesem Rahmen wird eine empirische Erfassung der aktuellen Verbreitung und Anwendung von KI zusammen mit Anknüpfungspunkten zur Ressourceneffizienz vorgenommen. Es zeigt sich, dass Ressourceneffizienz aktuell in den seltensten Fällen die Grundmotivation zur betrieblichen Anwendung von KI darstellt. Trotzdem ist die Steigerung der Ressourceneffizienz oft ein positiver Nebeneffekt beim Einsatz von KI. Die Studie gibt einen umfangreichen Überblick über derartige Anwendungsszenarien und Praxisbeispiele. Es wird festgestellt, dass weiterer Forschungsbedarf bezüglich des Einsatzes von KI, inklusive der Untersuchung möglicher negativer Effekte durch erhöhten Energieverbrauch für Rechenleistung oder Rohstoffverbrauch für die erforderliche Informations- und Kommunikationstechnologie (IKT), besteht. Zudem ist das Thema KI durch Forschung speziell für KMU zu unterstützen. Außerdem muss die Nachvollziehbarkeit von Bildungsangeboten für KI verbessert werden.

EXECUTIVE SUMMARY

In society, questions of resource efficiency and sustainable production are becoming increasingly important, which is also prompting companies to address more strongly the issue. Through the use of artificial intelligence (AI), companies have been able to realize operational efficiency gains in order to achieve competitive advantages, among other things. So far, these successes have only been transferred to a limited extent to operational resource efficiency. The potentials associated with this have been recognized in principle but have so far only been insufficiently qualified and quantified. The qualitative gap is addressed by the present study on "Potentials of Weak Artificial Intelligence for Operational Resource Efficiency" by aiming at the efficient use of material, energy, and water as well as the reduction of the resulting greenhouse gas emissions. Quantitative statements are difficult due to insufficient data. The topics of AI and resource efficiency are considered integratively and brought into the context of operational practice. The study is based on a methodical literature research, a survey of small and medium-sized enterprises (SMEs) and larger companies as well as on expert interviews. The main target group of the study is SMEs. For them, potentials for increasing resource efficiency are identified and incentives for the use of AI are created. Within this framework, an empirical survey of the current dissemination and application of AI is carried out together with links to resource efficiency. Overall, it is shown that resource efficiency currently represents the basic motivation for the operational application of AI in the rarest of cases. Nevertheless, resource efficiency is in many cases a positive side effect of the use of AI. The study provides a comprehensive overview of such application scenarios and practical examples. It is concluded that there is a need for further research on the use of AI, including the investigation of possible negative effects due to increased energy consumption for computing power or raw material consumption for the required information and communication technology. In addition, the topic of AI must be supported by research specifically for SMEs. The comprehensibility of and educational opportunities for AI must be improved.

1 EINLEITUNG

Ressourceneffizienz und künstliche Intelligenz sind Themengebiete, deren integrierte Betrachtung die Grundlage für die vorliegende Studie bildet. Zu Beginn der Studie werden die beiden Begrifflichkeiten definiert und die Motivation für ihre Betrachtung herausgearbeitet. Prof. Dr.-Ing. Alexander Sauer (Universität Stuttgart und Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA) gibt in einem Experteninterview ergänzende Einblicke in das Thema - mit Fokus auf kleine und mittlere Unternehmen (KMU). Des Weiteren werden die Zielsetzung der Studie erläutert, die wesentlichen Forschungsfragen aufgezeigt sowie die Methodik zur Beantwortung präsentiert.

1.1 Motivation

Durch künstliche Intelligenz (KI) können konkrete Anwendungsprobleme mithilfe von Computerprogrammen gelöst werden, welche üblicherweise menschliche Intelligenz erfordern. Durch Algorithmen und Daten sind Systeme der KI zur Selbstoptimierung fähig. In Abschnitt 2.1 werden die grundlegenden Begriffe zum Themenkomplex künstliche Intelligenz ausführlich diskutiert. Zu den typischen Aufgabenfeldern der KI zählen beispielsweise Klassifikation, Segmentierung und Regression. Auf diese Weise können Anwendungsfelder wie die Ursachenanalyse oder das Text- und Bildverständnis automatisiert werden.

Im Unternehmenskontext ist die Einführung von KI häufig mit dem Ziel der Erhöhung der Effizienz betrieblicher Prozesse durch Automatisierung von Routinetätigkeiten verbunden. Unternehmen gewinnen an Flexibilität und Anpassungsfähigkeit und verschaffen sich somit einen Wettbewerbsvorteil. Durch die Fähigkeit von KI, die Auswertung sehr großer Datenmengen zu ermöglichen, werden bestimmte Problemstellungen überhaupt erst lösbar¹.

¹ Vgl. Senior, A. W.; Evans, R.; Jumper, J.; Kirkpatrick, J.; Sifre, L.; Green, T.; Qin, C.; Židek, A.; Nelson, A. W. R.; Bridgland, A.; Penedones, H.; Petersen, S.; Simonyan, K.; Crossan, S.; Kohli, P.; Jones, D. T.; Silver, D.; Kavukcuoglu, K. und Hassabis, D. (2020).

Dass sich KI-Lösungen auch in KMU realisieren lassen, zeigen verschiedene aktuelle Studien². Fragestellungen der Ressourceneffizienz und der nachhaltigen Produktion nehmen in der Gesellschaft einen immer höheren Stellenwert ein. Dies veranlasst Unternehmen dazu, sich künftig stärker mit künstlicher Intelligenz in diesem Kontext zu beschäftigen und unererschlossene Potenziale zu identifizieren. Potenziale von KI für die betriebliche Ressourceneffizienz wurden bisher allerdings unzureichend untersucht. Diese Lücke soll nun mit der vorliegenden Studie geschlossen werden.

1.1.1 Ressourceneffizienz in der betrieblichen Praxis

Seit der Pariser Klimakonferenz 2015 und der als Folge beschlossenen Begrenzung der globalen Erwärmung auf unter 2 °C (verglichen zum präindustriellen Zeitalter), rückt die Verringerung der menschengemachten Umweltwirkungen zunehmend auf die politische und gesellschaftliche Agenda. Als Folge verabschiedete das Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit (BMU) im Jahr 2016 den nationalen Klimaschutzplan. Dieser sieht eine Reduktion der Treibhausgasemissionen bis 2030 um mindestens 55 %; im Vergleich zum internationalen Referenzjahr 1990 vor. Im nationalen Klimaschutzplan wird die Industrie als relevantes Handlungsfeld identifiziert und es werden detaillierte Zielstellungen und Maßnahmen abgeleitet³. So trug der industrielle Sektor im Jahr 2018 mit 22,5 % zur gesamten Treibhausgasbilanz Deutschlands bei. Davon entstammen 15 % aus der notwendigen Energiebereitstellung; der übrige Anteil entfällt auf industrielle Prozesse⁴.

Als eine dieser Maßnahmen wurde vor wenigen Jahren für sämtliche Unternehmen, die gemäß EU-Definition nicht als KMU klassifiziert sind, ein Energieaudit verpflichtend⁵. Ziel dieser gesetzlich vorgeschriebenen Auditierung ist die Ableitung von Energieeffizienzpotenzialen auf Basis einer zuvor durchgeführten Bilanzierung von Energieverbrauchsdaten. Einige

² Vgl. Deloitte Private (2021).

³ Vgl. BMU (2016).

⁴ Vgl. Umweltbundesamt (2021).

⁵ Vgl. Bundesamt für Wirtschaft und Ausfuhrkontrolle (2020).

Unternehmen gehen noch einen Schritt weiter und etablieren ein Energiemanagementsystem nach DIN EN ISO 50001⁶. Die genannte Verpflichtung sowie die vergleichsweise geringe Komplexität der Identifikation und Umsetzung erster Energieeffizienzmaßnahmen führten zu einer starken Konzentration auf die Ressource Energie, sobald Bemühungen zur Reduktion der betrieblichen Umweltwirkungen angestrengt wurden. Diese Fokussierung vernachlässigt jedoch zentrale natürliche und betriebliche Ressourcen. Ganzheitliche Optimierung kann nur unter Einbezug auch aller natürlichen Ressourcen stattfinden. So tragen bei einer ökologischen Bilanzierung über Scope 1 bis 3 nach dem anerkannten Standard des Greenhouse Gas Protocols unter anderem auch sämtliche eingebrachten Produktions-, Verbrauchs- und Hilfsstoffe zur Umweltwirkung der Unternehmung bei⁷. Das erstmals im Jahr 2012 beschlossene deutsche Ressourceneffizienzprogramm (ProgRess I) sah bis 2020 eine Erhöhung der Rohstoffproduktivität um 100 % gegenüber dem Niveau von 1994 vor⁸. Dieses wurde jedoch mit einer erzielten Verbesserung in Höhe von rund 65 % deutlich verfehlt⁹. Entsprechend wurden die Ziele aktualisiert. Eine jährliche Erhöhung der Rohstoffproduktivität um 1,6 % bis zum Jahr 2030 wird in der Deutschen Nachhaltigkeitsstrategie von 2016 angestrebt. Das im Jahr 2020 neu aufgesetzte Deutsche Ressourceneffizienzprogramm ProgRess III nennt konkrete Maßnahmen zur Erreichung dieser Ziele. Unter anderem findet die Digitalisierung als relevanter Befähiger prominente Erwähnung¹⁰. Hinzu kommt der beträchtliche Beitrag der Materialkosten (42 %) zur Gesamtkostenstruktur des verarbeitenden Gewerbes¹¹. Die enorme Hebelwirkung von Materialeffizienzprogrammen wird entsprechend klar ersichtlich. Selbst kleine Materialeinsparungen schlagen sich oftmals in einem signifikanten wirtschaftlichen Vorteil nieder. Unternehmen des verarbeitenden Gewerbes streben folglich die Einsparung von Ressourcen und insbesondere Materialien an, um neben der Verringerung der eigenen

⁶ Vgl. DIN EN ISO 50001:2018.

⁷ Vgl. Bhatia, P.; Ranganathan, J.; Gage, P.; Corbier, L.; Schmitz, S. und Oren, K. (2004).

⁸ Vgl. BMU (2020).

⁹ Vgl. Umweltbundesamt (2020b).

¹⁰ Vgl. Umweltbundesamt (2020a).

¹¹ Vgl. Statistisches Bundesamt (2017).

Umweltwirkung im internationalen Wettbewerb bestehen zu können. Demnach ist festzuhalten, dass Ressourceneffizienz und Wirtschaftlichkeit keine widersprüchlichen, sondern in vielen Fällen ergänzende Zielstellungen sind.

Innerhalb der vorliegenden Studie werden unter betrieblichen Ressourcen sowohl die natürlichen Ressourcen Material, Wasser und Energie verstanden als auch die erzeugten Treibhausgas(THG-)Emissionen, welche über die Aufnahmefunktion bei den Ökosystemdienstleistungen (Senkenfunktion) ebenfalls in die natürlichen Ressourcen einzuordnen sind. Da für die Produktion von Betriebsstoffen und Maschinen Materialien und Energie benötigt werden, bestehen auch sie aus den natürlichen Ressourcen, die in dieser Studie als Teilmenge der betrieblichen Ressourcen betrachtet werden. Menschen und Zeit sind in dieser Studie ausdrücklich im Begriff der betrieblichen Ressourcen nicht enthalten.

Die Steigerung der Ressourceneffizienz ist ein zentraler Hebel, um Umweltwirkungen und gleichzeitig Kosten zu senken. Trotz dieser Vorteile wird Ressourceneffizienz in Unternehmen oft als Nebeneffekt angesehen und nicht gezielt vorangetrieben. Verschiedene Stakeholder - wie Politik, Kunden oder Investoren - legen schon heute vermehrten Fokus auf dieses Thema und fordern eine effiziente Strategie zur Verbesserung der unternehmerischen Nachhaltigkeitsperformance, insbesondere im Bereich der Klimaneutralität. Dieses Ziel kann nur unter Einbezug der Ressourceneffizienz in der betrieblichen Praxis gelingen. Dies betonte auch Prof. Dr.-Ing. Alexander Sauer, Leiter des Instituts für Energieeffizienz in der Produktion EEP der Universität Stuttgart und Leiter des Fraunhofer-Instituts für Produktionstechnik und Automatisierung IPA.

Interview Prof. Dr.-Ing. Alexander Sauer

Wie nehmen Sie die Bereitschaft von KMU wahr, sich der Aufgabe der Verringerung der eigenen Umweltwirkungen zu stellen?

Prof. Sauer: Während vor einigen Jahren nur wenige Vorreiter das eigene Unternehmen aus intrinsischer Motivation heraus auf einen ökologisch nachhaltigen Pfad brachten, nimmt das diesbezügliche Interesse derzeit signifikant zu. Diese Entwicklung ist über diverse Branchen und

Firmengrößen hinweg zu beobachten. Dabei setzen verschiedenste Treiber Anreize, sich der Verringerung der eigenen Umweltwirkungen anzunehmen. Während eine steigende Anzahl interner und externer Stakeholder Klimastrategien von den Unternehmen erwartet, sind in den folgenden Jahren zudem sich verschärfende Vorgaben und Regularien seitens des Gesetzgebers zu erwarten. Dies lässt mehr und mehr Unternehmen tätig werden.

Auch wenn KMU oftmals nur begrenzten Zugriff auf Kapazitäten zur Erarbeitung und insbesondere zur Realisierung einer Klimastrategie haben, sind direkte Entscheidungsstrukturen und höhere Flexibilität relevante Befähiger bei der Umsetzung einer nachhaltigen Produktion. Dies beobachten wir anhand diverser Projekte und Fallstudien, die wir derzeit am Fraunhofer IPA bearbeiten. Hierzulande wird KMU eine starke Innovationskraft attestiert. Viele Unternehmen nutzen ebendiese, um sich durch eine nachhaltige Ausrichtung strategisch sinnvoll zu positionieren.

Welche Potenziale bietet Ressourceneffizienz im industriellen Umfeld bei der Erreichung von Klimazielen?

Prof. Sauer: Wir leben in einer Gesellschaft, in der das Wachstum die zentrale Leitmaxime unserer Art des Wirtschaftens ist. Bereits heute agieren wir außerhalb unserer planetaren Grenzen und verbrauchen mehr Ressourcen als unsere Erde regenerieren kann. Im Hinblick auf die wachsende Weltbevölkerung und das weiterhin ansteigende Konsumbedürfnis, muss die Ressourceneffizienz signifikant erhöht werden. Folglich benötigen wir kurz- bis mittelfristig eine massive Entkopplung von Wachstum und Ressourcenverbrauch. Eng verknüpft ist der Ressourcenbedarf mit nahezu sämtlichen ökologischen Auswirkungen menschlicher Geschäftstätigkeit. Von der Gewinnung über die Aufbereitung und den Transport fallen Umweltwirkungen an, die beschlossene Klimaziele in weite Ferne rücken lassen. Eine Verringerung des Ressourcenbedarfs innerhalb der Produktion hat somit direkten Einfluss auf die Emissionsintensität von Prozessen, Produkten und folglich unsere konsumierende Gesellschaft. Betriebliche Ressourceneffizienz unterstützt somit sowohl die Erreichung individueller als auch gesamtgesellschaftlicher Klimaziele.

Wie bewerten Sie den Beitrag von KI zur Erhöhung der Ressourceneffizienz von KMU?

Prof. Sauer: Die Digitalisierung als solche gilt bereits seit einiger Zeit als zentrales Instrument zur Verbesserung der Nachhaltigkeitsperformance produzierender Unternehmen. Die Analyse großer Datenmengen sowie die damit einhergehende Ableitung möglicher Optimierungsmaßnahmen sind oft nur mit der Etablierung von Digitalisierungslösungen möglich.

Die Einbindung von Methoden der KI ist der konsequente nächste Schritt auf dem Weg zur Ausschöpfung von Ressourceneffizienzpotenzialen in Produktionsumgebungen. Auch für KMU bieten sich Chancen, durch zielgerichtete Einbindung von KI Wettbewerbsvorteile zu erzielen und Alleinstellungsmerkmale zu stärken oder zu etablieren.

1.1.2 Das KI-Ökosystem in Deutschland

Seit der Prägung des Begriffs „künstliche Intelligenz“ auf einer Konferenz am Dartmouth College in Hanover, New Hampshire (USA) im Jahr 1956 entwickelte sich dieses multidisziplinäre Forschungsfeld permanent weiter. Spätestens als IBMs Deep Blue 1997 den damals amtierenden Schachweltmeister Garry Kasparov in einem regulären Schachspiel schlagen konnte¹², ist das Thema künstliche Intelligenz auch in der Wahrnehmung der deutschen Gesellschaft angekommen. Damit rücken ebenso industrielle Anwendungen in den Fokus der Forschung. Im November 2018 wurde die „Strategie Künstliche Intelligenz der Bundesregierung“¹³ veröffentlicht. Damit wurde nicht nur das Gütesiegel „AI made in Germany“ ins Leben gerufen, sondern auch der Grundstein zum Auf- und Ausbau eines KI-Ökosystems gelegt, welches Deutschland zu einem weltweit führenden KI-Standort machen soll.

¹² Vgl. Newborn, M. (2003).

¹³ Vgl. Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2018).

Als Teil dieses Ökosystems vertritt der KI Bundesverband e. V. mehr als 300 innovative KMU, Startups und Entrepreneur*innen, die sich mit der Entwicklung und Anwendung von KI beschäftigen. Ziel ist, ein aktives, erfolgreiches und nachhaltiges KI-Ökosystem in Deutschland und Europa aufzubauen und weiter zu fördern. Darüber hinaus trägt der KI Bundesverband – auch mit seinen Regionalgruppen – dazu bei, Deutschland als KI-Wirtschaftsstandort zu stärken. Allerdings gibt es in vielen Branchen noch Nachholbedarf. Deshalb hat der KI Bundesverband Arbeitsgruppen aufgebaut. So werden beispielsweise in der Arbeitsgruppe „Industry 4.0 & Manufacturing“ spezifische Fragestellungen zu KI im produzierenden Gewerbe bearbeitet.¹⁴

Ein Thema, welches den KI Bundesverband besonders beschäftigt, betrifft die Herausforderungen, die mit der globalen Erwärmung einhergehen¹⁵. Die Wahrnehmung in diesem Kontext ist ambivalent. Künstliche Intelligenz wird entweder als Heilsbringer oder Klimasünder dargestellt. Die Arbeitsgruppe „Klima“ setzt sich deswegen kritisch mit dem Einsatz von KI im Rahmen der Nachhaltigkeit auseinander. Es werden einerseits Chancen und Handlungsfelder für Politik und Wirtschaft, andererseits auch Risiken, wie Rebound-Effekte oder mögliche signifikante Energieverbräuche der KI-Infrastruktur und Möglichkeiten zu ihrer Minimierung, diskutiert.

Neben dem KI Bundesverband gibt es viele regionale Initiativen mit dem Ziel, Wissen zu vermitteln und den breiten Einsatz künstlicher Intelligenz in Unternehmen der jeweiligen Region zu fördern. Damit formen sie durch ihre Arbeit das bundesweite KI-Ökosystem. Als Beispiel für eine regionale Initiative wird im Folgenden die Initiative „AI for Hamburg“ vorgestellt.

¹⁴ Vgl. KI Bundesverband (2020).

¹⁵ Vgl. Spreiter, L.; Witte, K.; Just, V.; Damm, P.; Bohnhoff, T.; Rahtgens, C.; Asanger, F.; Maas, S.; Britsch, C. und Förstner, F. (2021).

AI for Hamburg – Netzwerk zur Förderung von KI

Vorstellung von AI for Hamburg

Vor allem durch internationale KI-Expertise im wirtschaftlichen Kontext fördert AI for Hamburg¹⁶ das Wissen und den breiten Einsatz künstlicher Intelligenz und insbesondere des maschinellen Lernens in Unternehmen der Region.



Die Initiative AI for Hamburg wurde 2019 von verschiedenen Partnerinnen und Partnern gegründet und etabliert. Ziel ist die Metropolregion Hamburg zum Leuchtturm der künstlichen Intelligenz in Europa weiter zu entwickeln. Die entsprechenden KI-Wachstumswahlen 2020 sind in Abbildung 1 visualisiert.

Hemmnisse von KMU für den Einsatz von KI

Das Thema KI ist insbesondere im Mittelstand noch mit viel Unwissenheit und Unsicherheiten behaftet. Es fehlt das Vertrauen in die Technologie, und KI-Lösungsanbieter sind oft nicht bekannt. Weitere Hemmnisse für zahlreiche KMU sind die fehlende Verfügbarkeit von Daten und die Frage nach der Finanzierung der Maßnahmen. Es ist oft nicht ersichtlich, welche Daten für KI-Anwendungen genutzt werden können oder welche Datenmenge und -qualität notwendig sind.

Vorteile einer regionalen Technologie-Plattform für KMU

AI for Hamburg vermittelt über diverse Kanäle und Veranstaltungen, welche Lösungen heute mit KI umgesetzt werden können. Damit soll insbesondere der Mittelstand unterstützt werden, um die entsprechenden Chancen und Risiken besser zu verstehen, smarte Lösungskonzepte zu entwickeln und Partner für die Umsetzung zu finden.

¹⁶ Vgl. AI.HAMBURG (2021).

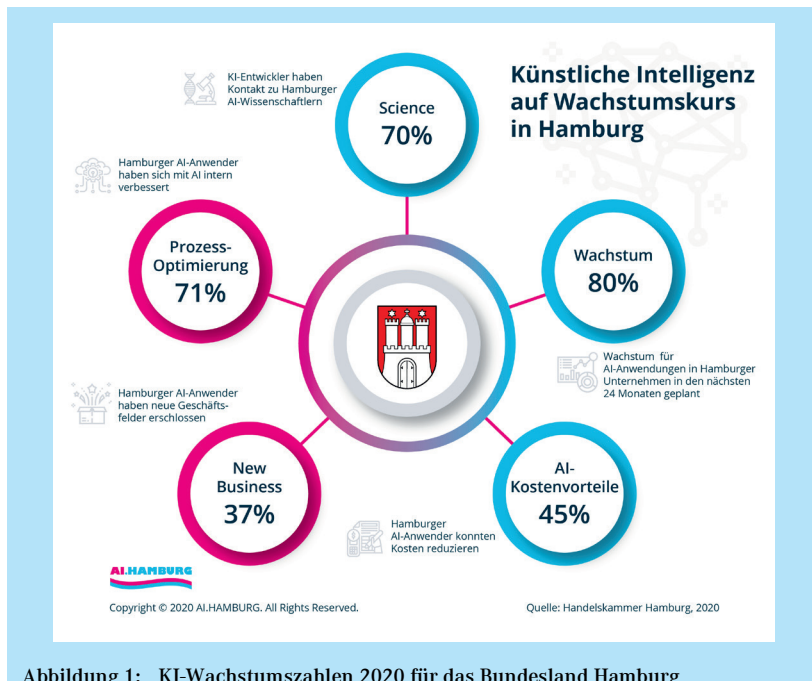


Abbildung 1: KI-Wachstumszahlen 2020 für das Bundesland Hamburg

Obwohl die Einsatzmöglichkeiten von KI zur Steigerung der gesellschaftlichen Nachhaltigkeit bzw. beim Klimaschutz bereits vielfach diskutiert sind¹⁷, finden Anwendungsfelder von KI für die Ressourceneffizienz im verarbeitenden Gewerbe eher geringe Beachtung in der öffentlichen Debatte.

KMU stehen vor großen Herausforderungen bei der Adaption neuer Technologien, da die verfügbaren personellen, wirtschaftlichen, zeitlichen und auch natürlichen Ressourcen begrenzt sind und der Spielraum zum Experimentieren klein ist. Dies trifft vor allem bei der Einführung von KI zu, da neben technischen Ressourcen (Soft- und Hardware) auch eine (digitalisierte) Datenbasis vorhanden sein muss. Zudem sind neue Fähigkeiten von Mitarbeitenden gefordert¹⁸. Dies und wie die Einführung von KI im Mittel-

¹⁷ Vgl. Kaack, L. H.; Donti, P. L.; Strubell, E. und Rolnick, D. (2020).

¹⁸ Vgl. Lundborg, M. und Märkel, C. (2019).

stand gelingen kann, zeigen beispielsweise Untersuchungen der VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik¹⁹ und des Mittelstand 4.0-Kompetenzzentrums Dortmund²⁰. Außerdem existieren mittlerweile auch praktisch ausgerichtete Hilfsangebote zur Auswahl, Initiierung und Umsetzung von KI-Projekten in KMU. Ein Beispiel dafür ist die „KI-Sprechstunde“ von „_Gemeinsam digital“²¹, dem Mittelstand 4.0-Kompetenzzentrum Berlin. Die KI-Sprechstunde mit KI-Trainerinnen und Trainern bildet die erste Anlaufstelle für KMU und unterstützt dabei, relevante Anwendungsszenarien zu finden. Es werden Hinweise für weiterführende Kooperationen mit Netzwerkpartnern gegeben und geeignete Technologiedienstleistungen am Markt erörtert²². Allerdings fehlt es diesen Hilfsangeboten an Bekanntheit, um zu einer umfassenden Transformation des Mittelstandes beitragen zu können.

Neben den zuvor genannten Hilfsangeboten existieren auch vielfältige Förderungsmöglichkeiten für KMU wie beispielsweise das Förderprogramm „KI-Leuchttürme“. Das Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit (BMU) fördert mit der Initiative „KI-Leuchttürme für Umwelt, Klima, Natur und Ressourcen“ Projekte, in welchen KI entwickelt und genutzt wird, um ökologische Herausforderungen anzugehen und welche zudem als Beispiel für eine ressourcenschonende Digitalisierung stehen.²³

1.2 Zielsetzungen

Das Ziel der Studie ist es, den Einfluss von KI im Hinblick auf die betriebliche Ressourceneffizienz bezogen auf die natürlichen Ressourcen Wasser, Energie, Material und Treibhausgase im verarbeitenden Gewerbe zu erörtern. Der Fokus liegt dabei auf KMU. Bei diesen stellen die Implementierung und Umsetzung von KI oftmals eine große Herausforderung dar, die jedoch auch mit Chancen verbunden ist. Die Studie fokussiert bewusst

¹⁹ Vgl. VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik (2020).

²⁰ Vgl. Mittelstand 4.0 Kompetenzzentrum Dortmund (2020).

²¹ Vgl. Gemeinsam digital (2021).

²² Vgl. Witte, K. und Gradl, M. (2021).

²³ Vgl. Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit (2021).

KMU, da hier häufig die Zeit und das Personal fehlen, um sich einen Überblick über die Möglichkeiten von KI und den damit verbundenen Methoden sowie Technologien verschaffen zu können. Auch das nötige Fachwissen zur Auswahl und Umsetzung von KI-Projekten im eigenen Betrieb ist oftmals nicht vorhanden. Deshalb soll die Studie nicht nur KI-Beispiele für die betriebliche Ressourceneffizienz aufzeigen, sondern ebenfalls praktische Hilfestellungen bei der Umsetzung im eigenen Betrieb bieten. Die Studie orientiert sich entsprechend an folgenden Fragestellungen:

Forschungsfragen der Studie

- Welche Technologien und Methoden der schwachen KI können KMU des verarbeitenden Gewerbes verwenden, um ihre betriebliche Ressourceneffizienz zu steigern?
- Welche Potenziale hinsichtlich betrieblicher Ressourceneffizienz ermöglicht schwache KI bei KMU des verarbeitenden Gewerbes?
- Welche Anwendungsszenarien von schwacher KI sind am vielversprechendsten, um die betriebliche Ressourceneffizienz in KMU zu steigern?
- Welche Erfolgsfaktoren und Hemmnisse existieren für die systematische Anwendung von schwacher KI zur Steigerung der betrieblichen Ressourceneffizienz in KMU?
- Welche Umsetzungsbeispiele bestehen für eine erfolgreiche Steigerung der betrieblichen Ressourceneffizienz in KMU durch den Einsatz schwacher KI?
- Welche Handlungsfelder ergeben sich für KMU, Wissenschaft und Politik?

Im Rahmen dieser Studie zählen inhabergeführte Unternehmen mit weniger als 1.000 Mitarbeitenden zu KMU – eine Beschränkung nach Umsatz oder Bilanzsumme gibt es nicht.

1.3 Methodisches Vorgehen

Zunächst werden einige zentrale Begriffe der Studie definiert (Kapitel 2). Ausgangspunkt, um die Forschungsfragen zu beantworten, ist eine systematische Literaturrecherche zum aktuellen Forschungsstand von KI-Anwendungsszenarien entlang der Wertschöpfungskette von produzierenden Unternehmen, welche einen Einfluss auf die betriebliche Ressourceneffizienz haben. Die Ergebnisse dieser Literaturrecherche fließen in die Konzeptionierung einer Expertenbefragung in Form einer Onlineumfrage ein. Ziel ist, die praktische Relevanz der recherchierten Anwendungsszenarien zu untersuchen und diese weiter hinsichtlich ihrer Erfolgsfaktoren und Hemmnisse sowie deren Einfluss auf die betriebliche Ressourceneffizienz zu qualifizieren (Kapitel 3). Anschließend wird eine Methodik zur Potenzialanalyse von Anwendungsszenarien einschließlich eines Reifegrad- und Kennzahlenmodells vorgestellt. Mit dieser kann die Einsparung von Ressourcen durch schwache KI messbar gemacht werden (Kapitel 4). In Kapitel 5 wird die Potenzialanalyse an acht ausgewählten Anwendungsszenarien beispielhaft durchgeführt. Die Anwendungsszenarien werden mit erfolgreichen Praxisbeispielen aus KMU untermauert. Kapitel 6 widmet sich den Erfolgsfaktoren und Hemmnissen bei der Implementierung von KI. In Kapitel 7 werden die Handlungsfelder für KMU, Politik und Wissenschaft abgeleitet und ausgearbeitet. Die Studie wird mit einer Zusammenfassung und einem Fazit in Kapitel 8 abgeschlossen.

2 GRUNDLAGEN UND BEGRIFFE

In diesem Kapitel werden die Grundlagen und zentralen Begriffe in den Themengebieten der künstlichen Intelligenz und Ressourceneffizienz erläutert. Als Ergebnis einer Literaturrecherche werden typische Anwendungsszenarien von KI mit einer dokumentierten Auswirkung auf Ressourceneffizienz aufgezeigt. Dieses Potenzial wird durch eine Expertenbefragung in Kapitel 3 und Anwendungsszenarien sowie Praxisbeispiele in Kapitel 5 weiter quantifiziert und qualifiziert.

2.1 Schwache künstliche Intelligenz

In der Literatur finden sich zahlreiche Definitionen zu KI und bis heute gibt es keine einheitliche Begriffserläuterung. Dies liegt daran, dass KI ein multidisziplinäres Forschungsfeld beschreibt, welches eine Vielzahl von Methoden und Technologien zusammenfasst. Was sie eint, ist die Ambition, Systeme zu entwickeln, die menschliche Kognition nachempfinden und sogar übertreffen.

Im Allgemeinen wird zwischen „schwacher“ und „starker“ KI („artificial narrow intelligence“ vs. „artificial general intelligence“) unterschieden. Dabei zeichnet sich „starke“ KI vor allem dadurch aus, dass sie kognitive Fähigkeiten besitzt, die dem Menschen in nahezu allen Aspekten überlegen oder mit ihm gleichauf ist. Im Gegensatz dazu kann „schwache“ KI zwar dem Menschen überlegen sein, ist dies jedoch meist nur in den Bereichen, für die sie explizit programmiert und trainiert wurde²⁴. Die von der breiten Öffentlichkeit wahrgenommenen Durchbrüche von KI, etwa durch IBM bei der Quizshow Jeopardy und DeepMind beim Schach bzw. Go, stellen somit auch Anwendungsszenarien „schwacher“ KI dar. Zwar sind diese Systeme in ihren jeweiligen Domänen dem Menschen deutlich überlegen, allerdings besitzen sie abseits davon keinerlei Fähigkeiten. Grundsätzlich lässt sich festhalten, dass es bis heute noch nicht gelungen ist, eine allgemeine, „starke“ KI zu entwickeln. Dementsprechend liegt der Fokus dieser Studie auf „schwacher“ KI, sodass der für den Rest dieser Studie verwendete

²⁴ Vgl. Bostrom, N. und Yudkowsky, E. (2014).

te Begriff „KI“ als Synonym dafür zu betrachten ist. Nichtsdestotrotz ist „starke“ KI ein Thema, welches die Forschung weiterhin beschäftigt und das es zu beobachten gilt²⁵.

Abgrenzung von schwacher zu starker KI

- Die „schwache“ KI ist fokussiert auf die Lösung konkreter Anwendungsprobleme auf Basis bekannter Methoden aus der Mathematik und Informatik. Die entwickelten Systeme sind dabei zur Selbstoptimierung fähig. Dazu werden auch Aspekte menschlicher Intelligenz nachgebildet und formal beschrieben bzw. Systeme zur Simulation und Unterstützung menschlichen Denkens konstruiert.²⁶
- Ausschlaggebendes Kriterium der „starken“ KI ist, dass entsprechende KI-Systeme in großer Breite die gleichen intellektuellen Fähigkeiten wie der Mensch haben oder ihn darin sogar übertreffen können²⁷.

Aus technologischer bzw. methodischer Perspektive sind die Algorithmen und Modelle „schwacher“ KI dem Bereich des Maschinellen Lernens (ML) zuzuordnen. Dieser Begriff wurde bereits 1959 durch Arthur Samuel geprägt. Er beschrieb damit ein Programm, das in der Lage ist, ein bestimmtes Verhalten zu erzeugen, das nicht explizit im Rahmen der Programmierung vorgegeben wurde²⁸. Heute wird im Kontext des ML meist zwischen überwachtem („supervised“) und unüberwachtem („unsupervised“) Lernen unterschieden. Einen weiteren, spezielleren Fall des ML stellt zudem das verstärkende Lernen („Reinforcement Learning“) dar. Für alle drei Bereiche gibt es zahlreiche Anwendungsbeispiele, die bereits heute implementiert sind und für die meist von sogenannten tiefen neuronalen Netzen („Deep Neural Networks“) Gebrauch gemacht wird. Diese haben sich als besonders performant herausgestellt und sind einer der wesentlichen Treiber für die

²⁵ Vgl. Marcus, G. (2020).

²⁶ Vgl. Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2018).

²⁷ Vgl. Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2018).

²⁸ Vgl. Joshi, A. V. (2020).

großen Fortschritte in der Anwendung von KI in den letzten zehn Jahren. So übernehmen ML Algorithmen bzw. schwache KI vielfältige Aufgaben in den verschiedensten Bereichen - von Sprach- und Objekterkennung, eigenständiger Steuerung von Fahrzeugen bis hin zur Ableitung von Handlungsempfehlungen in Expertensystemen.

Eine Übersicht etablierter KI-Methoden findet sich in Anhang A. Das sich rasant entwickelnde Forschungsfeld der künstlichen Intelligenz generiert regelmäßig neue oder erweitert bestehende Methoden. Aus diesem Grund erhebt Anhang A keinen Anspruch auf Vollständigkeit. Vielmehr soll ein Eindruck von der Breite der momentan vorhandenen Lösungsansätze vermittelt werden.

2.1.1 Überwachtes Lernen (Supervised Learning)

Methoden des überwachten Lernens zeichnen sich dadurch aus, dass sie implizite und explizite Zusammenhänge zwischen Input- und Output-Variablen lernen können. So lernt der Algorithmus beispielsweise anhand zuvor entsprechend markierter Bilddateien, ob auf neuen und ihm unbekanntem Bildern jeweils eine Katze oder ein Hund abgebildet ist. Dafür ist es beim überwachten Lernen zwingend erforderlich, dass Trainingsdaten mit entsprechenden Markierungen bzw. Labels vorhanden sind. Die beiden verbreitetsten Anwendungen für überwachtes Lernen sind die Klassifikation sowie die Regression. Diese werden im Folgenden vorgestellt und anhand geeigneter Beispiele ausgeführt.

Klassifikation (Classification)

Das bereits angedeutete Beispiel der Bilder, die den Kategorien „Hund“ oder „Katze“ zugeordnet werden, gibt eine binäre Klassifikationsaufgabe wieder. Bei einer Klassifikation wird versucht, den jeweiligen Inputdaten eine der möglichen und vorgegebenen Ergebnisklassen zuzuordnen. Die Zahl der möglichen Klassen und die Anzahl der zuzuordnenden Labels sind dabei nicht auf zwei beschränkt; z. B. kann neben den existierenden Klassen „Hund“ und „Katze“ auch noch eine Klasse „Vogel“ hinzugefügt werden. In diesem Zusammenhang spricht man von „Multi-Class“ bzw. „Multi-Label“ Klassifikation. Allerdings sind Klassifikationen grundsätzlich stets an diskrete Ergebniswerte, d. h. eine endliche Zahl an Klassen, gebunden.

Ein weiteres Beispiel für eine binäre Klassifikation ist die Einteilung von fertig produzierten Gütern in die zwei Klassen „erfüllt die Qualitätsanforderungen“ beziehungsweise „erfüllt die Qualitätsanforderungen nicht“. Anhand der Auswertung von Produktionsdaten und der Anwendung eines Klassifikationsalgorithmus lässt sich die Ausschussware automatisiert erkennen.

Lineare und nichtlineare Regression

Im Gegensatz zur Klassifikation besteht die Aufgabe von Regressionsmodellen darin, stetige Werte vorherzusagen. Dabei arbeitet der Lernmechanismus analog zur Klassifikation: Anhand von Trainingsdaten mit entsprechenden Merkmalsausprägungen sowie dazugehörigen Ergebniswerten lernt der Algorithmus, Ergebnisse ihm unbekannter Daten zu generieren. „Wie hoch sind die Mietkosten für weitere Bürokapazitäten?“ oder „Wie hoch wird der Umsatz im nächsten Monat sein?“ sind klassische Beispiele für Fragen, die sich mit einer Regression beantworten lassen.

Auch wenn Klassifikation und Regression durchaus als verwandte Ansätze betrachtet werden können, so unterscheiden sie sich doch in einem wesentlichen Punkt: Verkürzt formuliert versuchen Klassifikationsalgorithmen vorherzusagen, ob eine Klasse oder ein Label den Inputdaten zugeordnet werden kann. Auf der anderen Seite ist das Ziel von Regressionsalgorithmen, eine Vorhersage zu treffen, im Sinne von wie groß (oder klein) der Ergebniswert sein wird²⁹.

2.1.2 Unüberwachtes Lernen (Unsupervised Learning)

Im Gegensatz zum überwachten Lernen den Trainingsdaten sind beim unüberwachten Lernen keine entsprechenden Labels zugeordnet. In Abwesenheit dieser zielen die Ansätze daher darauf ab, die zur Verfügung stehenden Trainingsdaten grundsätzlich zu charakterisieren und darauf basierend, je nach Zielstellung, Schlussfolgerungen zu ziehen. Die den Daten inhärenten Muster werden also von dem Algorithmus ohne jegliche Rück-

²⁹ Vgl. Provost, F. und Fawcett, T. (2013).

meldung erkannt. Die klassischen Aufgaben für unüberwachtes Lernen sind das Clustering sowie die Dimensionsreduktion.

Clusteranalyse (Clustering)

Beim Clustering versucht der Algorithmus, die gegebenen Inputdaten basierend auf bestimmten Metriken miteinander in Verbindung zu setzen. Das wahrscheinlich gängigste Beispiel dafür ist die Segmentierung der Nutzerinnen und Nutzer oder Kundinnen und Kunden. Diese werden auf Basis ihrer Verhaltens- und Kaufmuster in ähnliche Cluster gruppiert, sodass individualisierte Angebote je Gruppe ausgespielt werden können. Zudem erweist sich das Clustering als äußerst hilfreich, um in explorativen Analysen natürliche Unterscheidungsmerkmale zu entdecken, und dient als Ausgangspunkt für weitere Entscheidungsprozesse³⁰. Oftmals können Ergebnisse des Clusterings auch als Input für Algorithmen des überwachten Lernens verwendet werden³¹.

Dimensionsreduktion (Dimension Reduction)

Durch die zunehmende Digitalisierung steigt in vielen Unternehmen und Institutionen die Menge verfügbarer Daten exponentiell an. Es zeigt sich jedoch, dass größere Datenmengen nicht zwangsläufig zu verbesserten Vorhersagen von ML-Algorithmen führen, da unwesentliche und redundante Informationen die Genauigkeit der Vorhersage beeinträchtigen können. Ziel der Dimensionsreduktion ist es daher, einen gegebenen Datensatz ohne entscheidenden Informationsverlust zu verkleinern, indem die Anzahl der untersuchten Variablen reduziert wird.

2.1.3 Verstärkendes Lernen (Reinforcement Learning)

Das verstärkende Lernen nimmt in der Kategorisierung von ML-Ansätzen eine gewisse Sonderrolle ein. Durch die aktive Einbindung von Feedback – in gleichzeitiger Abwesenheit von vorab markierten Trainingsdaten – sind die Methoden des verstärkenden Lernens, weder dem überwachten noch dem unüberwachten Lernen direkt zuzuordnen. Die zugrundeliegende Idee

³⁰ Vgl. Provost, F. und Fawcett, T. (2013).

³¹ Vgl. Danks, D. (2014).

beruht darauf, dass der Algorithmus mit seiner direkten und aufgabenspezifischen Umgebung interagiert. Dabei erhält er Rückmeldung in Form von positiven oder negativen Signalen, auf denen basierend er die jeweils angemessene Aktion bzw. Strategie lernen kann. Dabei wird der Algorithmus meist so ausgerichtet, dass er zwischen der Exploration seiner Umgebung und der Verwendung des bereits erlernten Wissens abwägt. Weitere spezifische Anwendungsszenarien lassen sich zudem in der Robotik und dem autonomen Fahren bzw. der eigenständigen Steuerung von Fahrzeugen finden.

2.2 Ressourcen und Ressourceneffizienz

Ressourcen

Ressourcen, ob materiell oder immateriell, bilden die Grundlage für jede unternehmerische Wertschöpfung. Im Folgenden wird der Begriff Ressource aus betriebswirtschaftlicher und politischer Sicht klassifiziert.

Ressourcen aus betriebswirtschaftlicher und politischer Sicht

- Aus betriebswirtschaftlicher Sicht umfassen **Ressourcen** alle ökonomisch notwendigen Faktoren für die Produktion – also insbesondere Betriebs- sowie Hilfsstoffe, Materialien sowie Werkstoffe, Energie, Kapital, Personal, Fachwissen und Zeit³².
- In der deutschen und europäischen Politik wird der Begriff Ressource demgegenüber im Sinne von **natürlichen Ressourcen** wie folgt definiert:

„Ressource, die Bestandteil der Natur ist. Hierzu zählen erneuerbare und nicht erneuerbare Primärrohstoffe, physischer Raum (Fläche), Umweltmedien (Wasser, Boden, Luft), strömende Ressourcen (z. B. Erdwärme, Wind-, Gezeiten- und Sonnenenergie) sowie die Biodiversität [siehe auch VDI 4800, Blatt 1³³].

³² Vgl. Schebek, L.; Abele, E.; Campitelli, A.; Becker, B. und Joshi, M. (2016).

³³ Vgl. VDI 4800 Blatt 1:2016-02.

Es ist hierbei unwesentlich, ob die Ressourcen als Quellen für die Herstellung von Produkten oder als Senken zur Aufnahme von Emissionen dienen.³⁴

Diese Studie folgt der Definition natürlicher Ressourcen der deutschen und europäischen Politik. Ergänzend dazu beschreibt die Richtlinie VDI 4800 Blatt 1 „Ressourceneffizienz – Methodische Grundlagen, Prinzipien und Strategien“ einen methodischen Rahmen zur Ermittlung und Bewertung von Ressourceneffizienz, welcher der vorliegenden Studie als Grundlage dient³⁵.

Da jedoch nicht alle natürlichen Ressourcen eine hohe betriebliche Relevanz besitzen oder Wechselwirkungen zu diesen bestehen, fließen in die Analyse der Ressourceneffizienz nur bestimmte Ressourcen ein, um die gesellschaftliche Zielstellung der Verringerung des Verbrauchs natürlicher Ressourcen mit betrieblichen Handlungsmöglichkeiten zu verknüpfen. Unter dem Begriff der betrieblichen Ressourcen werden daher innerhalb der Studie lediglich die natürlichen Ressourcen Material, Wasser und Energie verstanden als auch die erzeugten THG-Emissionen, welche über die Aufnahmefunktion bei den Ökosystemdienstleistungen (Senkenfunktion) ebenfalls in die natürlichen Ressourcen einzuordnen sind. Der Einsatz natürlicher Ressourcen lässt sich oft nur mit hohem Aufwand im Unternehmen selbst ermitteln, da sich der Verbrauch vielmehr aus den Vor- und Nachketten der jeweiligen betrieblichen Ressource ergibt. Ein Beispiel bildet die Produktion von Betriebsstoffen und Maschinen. Auch sie benötigen Materialien und Energie und bestehen somit ebenso aus natürlichen Ressourcen. Sie werden daher in dieser Studie als Teilmenge der betrieblichen und natürlichen Ressourcen betrachtet. Menschen und Zeit sind in dieser Studie ausdrücklich im Begriff der Ressourcen nicht enthalten.

³⁴ Vgl. Kosmol, J.; Kanthak, J.; Herrmann, F.; Golde, M.; Alsleben, C.; Penn-Bressel, G.; Schmitz, S. und Gromke, U. (2012).

³⁵ Vgl. VDI 4800 Blatt 1:2016-02.

Ressourceneffizienz

Nicht nur in der Wirtschaft, sondern auch in der Politik ist Ressourceneffizienz ein weit verbreiteter Begriff. In ihm kommt das unternehmerische Prinzip des effizienten Wirtschaftens mit dem der nachhaltigen Entwicklung zusammen. Nachhaltige Entwicklung strebt die Erhaltung des „Naturkapitals“ – der natürlichen Ressourcen der Gesellschaft – an. Dabei wird der Begriff der Ressourceneffizienz von der Richtlinie VDI 4800-1:2016-02 wie folgt definiert: „Verhältnis eines bestimmten Nutzens oder Ergebnisses zum dafür nötigen Ressourceneinsatz“³⁶. Ein solcher Nutzen kann im betrieblichen Umfeld die Herstellung eines Produktes, die Durchführung eines bestimmten Prozesses oder auch die Erbringung einer Dienstleistung sein. Bezogen auf diesen Nutzen in Form eines Gegenstands oder Sachverhalts folgt die Festlegung sogenannter Systemgrenzen (Systemrahmen), innerhalb derer die Ressourcenverbräuche zu ermitteln sind. Diese Festlegung der Systemgrenzen ist von der Fragestellung abhängig, erfasst aber meist den vollständigen Lebensweg im Sinne einer Ökobilanz nach DIN EN ISO 14040, um mögliche Problemverlagerungen auf vor- bzw. nachgeschaltete Prozesse identifizieren zu können.³⁷

2.3 Typische Anwendungsszenarien

Nachdem die Grundlagen aus den Bereichen der künstlichen Intelligenz sowie Ressourceneffizienz beleuchtet wurden, werden im Folgenden typische Anwendungsszenarien der schwachen KI im industriellen Umfeld vorgestellt. Diese wurden auf Basis einer Literaturrecherche identifiziert. In Kapitel 5 werden diese und weitere Anwendungsszenarien sowie deren Beitrag zur Ressourceneffizienz im Detail beschrieben.

Während der Literaturrecherche wurde auf die PRISMA-Methode zurückgegriffen. Aufgrund des Zeitpunkts der Literaturrecherche konnten Publikationen bis zum September 2020 einbezogen werden. Bei der PRISMA-Methode wird zunächst eine umfangreiche Grundgesamtheit an potenziell zutreffender Literatur mithilfe eines zielführenden, jedoch breit angelegten

³⁶ VDI 4800 Blatt 1:2016-02.

³⁷ Vgl. VDI Zentrum Ressourceneffizienz (2017).

Suchstrings in wissenschaftlichen Datenbanken, wie Scopus oder Google Scholar, identifiziert ($n = 1.347$). Der Suchstring umfasst die identifizierten KI-Methoden (siehe Anhang A) sowie die für diese Studie relevanten Ressourceneffizienzbegriffe Energie-, Material- und Wassereffizienz sowie Treibhausgasemissionen. Hinzu kommt weiterführende Literatur aus zusätzlichen Quellen, beispielsweise Verweise aus Gesprächen mit Fachexperten ($n = 49$). Im anschließenden PRISMA-Schritt werden zunächst Duplikate entfernt – die Grundgesamtheit verringert sich entsprechend ($n = 1.163$). Es folgt eine Vorabselektion der identifizierten Literatur. Hierfür werden sowohl Titel als auch Zusammenfassungen (Abstracts) der wissenschaftlichen Artikel gelesen und auf inhaltliche Übereinstimmung zum gewünschten Themenfeld überprüft. Hierdurch verbleiben 139 Publikationen, die einer Detailanalyse unterzogen werden. Durch das Lesen der Volltexte wird die jeweilige Sachdienlichkeit überprüft, wodurch weitere Quellen aus der folgenden Bearbeitung ausgeschlossen werden können, beispielsweise aufgrund fehlender Fokussierung auf das verarbeitende Gewerbe. Die verbleibenden 54 Publikationen werden einer weiterführenden Analyse unterzogen und hinsichtlich der Anwendungsszenarien und verwendeten KI-Methoden klassifiziert. Diejenigen Anwendungsszenarien, welche in der identifizierten Literatur mehrfach genannt werden, werden im Folgenden zusammenfassend beschrieben.

In den wenigsten Fällen gelingt die Umsetzung eines Anwendungsszenarios mit genau einer der in Abschnitt 2.1 beschriebenen Methoden des maschinellen Lernens. Zur Lösung eines konkreten Problems ist oftmals ein Zusammenspiel unterschiedlicher Methoden aus verschiedenen Fachgebieten (u. a. Statistik, Signalverarbeitung, ML) notwendig. Beispielsweise bietet es sich an, die Daten vorab anhand klassischer statistischer Verfahren zu bereinigen (z. B. mithilfe einer Ausreißeranalyse) und anschließend eine Dimensionsreduktion des Variablenraums vorzunehmen (unüberwachtes Lernen), bevor eine Regression oder Klassifikation (überwachtes Lernen) angewendet wird. Durch die sorgfältige Auswahl und geschickte Kombination der verschiedenen Methoden können häufig qualitativ hochwertigere Ergebnisse erzielt werden.

Predictive Maintenance

Die Anwendung „Predictive Maintenance“ oder auch voraussagende Instandhaltung wird durch die Aufnahme relevanter Zeitreihendaten über die Nutzungsdauer ermöglicht. Diese sollen den Zustand der zu analysierenden Infrastruktur abbilden und überwachen. Ziel ist Muster zu finden, um Ausfälle vorherzusagen und diese durch frühzeitige Instandhaltungsmaßnahmen zu verhindern. Dabei erfordert eine vorausschauende Wartung oft nicht mehr als eine vergleichsweise simple mathematische Berechnung: Zu welchem Zeitpunkt bedingt der Zustand einer Maschine die Reparatur oder gar den Austausch in effizientester Weise?

Anwendung finden hierbei unter anderem auch eine Vielzahl verschiedener Methoden der schwachen KI, wobei sich die Wahl der Methode ebenso auf die Komplexität der Implementierung auswirkt. So können einige Rechenmodelle beispielsweise mit vorhandenen Daten arbeiten und das nächste Wartungsintervall vorhersagen, ohne dass neue Sensorik oder Software installiert werden muss. Für andere Methoden wird eine spezifischere Datengrundlage benötigt, die beispielsweise die Installation von Kamerasystemen oder anderen Sensoren notwendig macht. Mit ihrer Hilfe können über komplexe ML-Algorithmen, wie beispielsweise neuronale Netze, Fehlerzustände in der Fertigung erkannt und Maßnahmen zur Prävention vorgeschlagen werden. Die oftmals notwendige Installation/Implementierung dieser Soft- und Hardware während des laufenden Betriebs der Produktionsinfrastruktur, ist eine weitere nicht zu vernachlässigende Hürde. Voraussetzung für einen erfolgreichen Einsatz der jeweiligen KI-Methoden für das Anwendungsszenario „Predictive Maintenance“ ist in jedem Fall eine solide Datenlage, auf deren Basis die Modelle trainiert werden und lernen können.

Durch den Einsatz von „Predictive Maintenance“ kann mittels effizient gewarteter Maschinen die Material- und Energieeffizienz signifikant erhöht werden, da ungewollte Material- und Energieverluste durch den Verschleiß der bearbeitenden Werkzeuge und Maschinen verhindert werden. Die Steigerung der Energieeffizienz führt wiederum zu einer Senkung der THG-Emissionen.

Produktionsplanung

Die Produktionsplanung kann mithilfe verschiedener ML-Methoden effizienter werden. Auf Basis historischer Fertigungsdaten können Algorithmen eingesetzt werden, um z. B. Bedarfe für die Zukunft zu ermitteln und so optimal ausgelegte Fertigungsstraßen zu konfigurieren. Durch Analyse und Klassifizierung unterschiedlicher Fertigungsmethoden, z. B. hinsichtlich Effizienz, kann die Produktionsplanung zusätzlich unterstützt werden. Hierzu finden insbesondere Methoden der Klassifizierung und Trendanalyse Anwendung. Häufig werden diese ML-Methoden mit sogenannten Expertensystemen kombiniert. Diese geben auf Basis von Realdaten und der Möglichkeit, die Informationen zu extrapolieren, Entscheidungshilfen und Handlungsempfehlungen aus. Dadurch kann der Aufwand einer Produktionsplanung teilweise stark verringert werden. Die Implementierung gestaltet sich meist unkompliziert, da die Methoden nicht in den laufenden Betrieb bzw. direkt an den Fertigungsanlagen installiert werden müssen. Eine solide Datengrundlage ist hierfür ebenfalls eine wichtige Basis, um die Funktionsfähigkeit der Modelle sicherzustellen.

Durch die verbesserte Produktionsplanung sind Reduktionen in den Bereichen Material- und Energieverbrauch und somit eine entsprechende Senkung der THG-Emissionen zu erzielen. Die Planung ist schlanker gestaltet und kann an spezifische Bedürfnisse angepasst werden.

Fehlererkennung und -vorhersage/Predictive Quality

Ein typischer Anwendungsbereich von schwacher KI im Bereich der Prozessoptimierung ist die Fehlererkennung in der Produktion. Diese kann insbesondere für eine automatisierte Qualitätskontrolle von Komponenten und Produkten eingesetzt werden. Zusätzlich ermöglichen einige Methoden eine Fehlervorhersage, mit der ein vorausschauender Eingriff in den Produktionsprozess (Prozesssteuerung) zur Fehlervermeidung ermöglicht wird. Methoden aus fast allen - von der Klassifizierung über die Segmentierung, Dimensionsreduktion sowie Bild- und Objekterkennung - werden für diese Anwendung eingesetzt. Voraussetzung für alle diese Methoden sind umfangreiche Datensätze, die beispielsweise durch die Installation von Sensorik und/oder Kamerasystemen zur Datenerhebung gewonnen

werden können. Diese sind zum Training der Algorithmen notwendig, um sie anschließend für die Fehlererkennung zu befähigen.

Bereits durch die reine Fehlererkennung kann die Ressourceneffizienz zum Teil signifikant verbessert werden. Die frühzeitige Fehlererkennung führt dazu, dass die Abweichungen im Prozess schnell korrigiert sowie die fehlerhaften Komponenten bzw. Produkte direkt aussortiert werden können. Dies verhindert das Durchlaufen nachfolgender Bearbeitungsprozesse – die einfließende Verschwendung von Ressourcen für Ausschussteile wird minimiert. Die Fehlervorhersage hat einen noch größeren Einfluss auf die Steigerung der Ressourceneffizienz, da das Entstehen von fehlerhaften Komponenten bzw. Produkten im Idealfall gänzlich verhindert wird. Die Haupteinsparungen sind demnach im Bereich Material zu erwarten. Zusätzlich geht ein verringerter Bearbeitungsaufwand für Ausschussteile auch mit einem geringeren Energiebedarf einher – entsprechend sind ebenfalls eine Erhöhung der Energieeffizienz und respektive Minderung der THG-Emissionen zu beobachten, auch bedingt durch die Reduktion der Materialien in der Vorkette.

Logistikplanung

Ähnlich der Produktionsplanung bietet auch die Logistikplanung Potenzial zur einfacheren, effizienteren und schnelleren Durchführung durch die Einbindung von KI-Methoden. Mithilfe diverser ML-Algorithmen werden anhand vergangener, aktueller und potenzieller zukünftiger Daten versteckte Muster, Regelmäßigkeiten und Unregelmäßigkeiten identifiziert. Diese Muster werden zur Entwicklung von Modellen verwendet, mithilfe derer nützliche Vorhersagen für das Einzelunternehmen getroffen werden können. Außerdem kann über offene Parameter der Basiszustand verändert werden, um mithilfe einer KI-gestützten Simulation verschiedene Szenarien zu untersuchen. Anhand der Ergebnisse der Szenarienanalyse kann das Logistiksystem angepasst und auf Ausnahmesituationen oder Ähnliches vorbereitet werden. Dies kann nicht nur auf die Beschaffung und Auslieferung von Produkten angewendet werden, sondern auch auf die Intralogistik innerhalb der eigenen Fertigungsanlage. Die Komplexität der Implementierung hängt primär von der Verfügbarkeit der Daten im Prozess der potenziellen ML-Anwendung ab; dazu kommen die Anforderungen der Anwendung an die Recheninfrastruktur/IT des Unternehmens. Müssen relevante

Anteile der benötigten Datensätze zunächst bereinigt oder gar beschafft werden, steigt der Aufwand zur Implementierung der Lösung signifikant an.

In der Logistikplanung ist es möglich, die THG-Emissionen sowie den Energieverbrauch zu reduzieren, indem u. a. Transportrouten optimiert und Leerfahrten vermieden werden.

Steigerung Energieeffizienz im Fertigungsprozess

Bei Fertigungsprozessen kann mithilfe verschiedener KI-Methoden die Energieeffizienz gesteigert werden. Hierzu werden historische Daten aus der Fertigung benötigt, um diese mithilfe der ML-Algorithmen aufzubereiten und Bedarfsvorhersagen bzw. -schätzungen für die Zukunft vorzunehmen. Neben Effizienzsteigerungen durch die Optimierung von Wartungsintervallen (siehe Abschnitt „Predictive Maintenance“) kann durch die Datenanalyse beispielsweise ein Expertensystem entwickelt werden.

Dieses gibt Handlungsempfehlungen hinsichtlich der Verringerung der betrieblichen THG-Emissionen oder des Energieverbrauchs. Dabei hängen die benötigte Datenmenge und KI-Methode von der jeweiligen Fertigungsmethode und dem konkreten Anwendungsszenario ab. Die Anwenderinnen und Anwender müssen entsprechend den optimalen Trade-off zwischen Implementierungsaufwand und gewünschter Aussagekraft identifizieren. Entsprechend sind allgemeingültige Aussagen hinsichtlich Soft- und Hardwareaufwänden schwer zu treffen. Nichtsdestotrotz kann festgehalten werden, dass gängige Methoden zur Steigerung der Energieeffizienz in der Fertigung häufig lediglich als unterstützendes Expertensystem angewendet werden und daher in den meisten Fällen nicht in die laufende Fertigung integriert werden müssen. Je nach Granularität der gewünschten Auswertung müssen jedoch ggf. Sensoren für eine verbesserte Datengrundlage nachgerüstet werden.

3 EXPERTENBEFRAGUNG

Um das Potenzial von schwacher KI in Bezug auf Ressourceneffizienz auch aus der betrieblichen Praxis zu betrachten, wird eine Expertenbefragung durchgeführt. Das Ziel ist es, die vorab formulierten Hypothesen zu überprüfen und Indizien zur Beantwortung der zentralen Forschungsfragen zu gewinnen. Dieser Teil der Studie fokussiert auf die Expertenbefragung von 71 Vertreterinnen und Vertretern aus Unternehmen. Dies ist aufgrund des Themas noch eine relative kleine Studienmenge. Trotzdem lassen sich wichtige Hinweise und Trends erkennen, die gegebenenfalls durch umfangreichere Studien noch stärker beleuchtet werden müssen.

Zu erwähnen ist die hohe Heterogenität hinsichtlich der jeweiligen Tätigkeitsschwerpunkte der befragten Unternehmen innerhalb des verarbeitenden Gewerbes. Zunächst wird auf die Konzeptionierung und Durchführung der Umfrage eingegangen. Anschließend finden eine Charakterisierung der Umfrageteilnehmenden und die Präsentation der Umfrageergebnisse statt. Das Kapitel endet mit einem Fazit, welches die Hauptideen der Expertenbefragung zum Potenzial von KI für die betriebliche Ressourceneffizienz zusammenfasst.

3.1 Methode

Insgesamt wurden 25 Hypothesen formuliert und in die folgenden Kategorien eingeteilt: Verbreitung, Anwendungsszenarien, Reifegradmodell, Ressourceneffizienz, Geschäftsmodelle, Hemmnisse und allgemeine Hypothesen. Eine Übersicht der Kategorien mit ausgewählten Hypothesen ist in Tabelle 1 dargestellt, die vollständige Liste an Hypothesen ist in Anhang B aufgeführt.

Tabelle 1: Ausgewählte Hypothesen je Kategorie

Kategorie	Hypothesen
Einsatz und Verbreitung von KI	Der Einsatz von KI findet sich nicht in der Unternehmensstrategie wieder.
Anwendungsszenarien	Typische Anwendungsszenarien sind: Predictive Maintenance, Produktionsplanung, Prozessoptimierung Fertigung - Fehlererkennung und -vorhersage, Bedarfsplanung, Steigerung Energieeffizienz im Fertigungsprozess, Steigerung Energieeffizienz im Gebäudemanagement
Motivation zur Einführung von KI	Die Steigerung der Ressourceneffizienz ist nicht die entscheidende Motivation für die Einführung von KI.
Ressourceneffizienz	Durch den Einsatz von KI kann die Ressourceneffizienz gesteigert werden.
Bedeutung von externen Partnern	Unternehmen setzen bei der Einführung von KI auf die Unterstützung von externen Partnern.
Unterschiede zwischen KMU und Großunternehmen	KMU zeigen im Vergleich zu Großunternehmen eine niedrigere Durchdringung von KI-Anwendungen.
Allg. Hypothesen	Die vorhandene technische Infrastruktur erschwert die Einführung von KI.

Bei der Konzeption des Fragebogens wurde eine strukturierte Form gewählt, deren Aufbau sich in zwei Abschnitte unterteilen lässt. Der erste Abschnitt enthält ein flexibles Fragenmodell, welches sich anhand der Beantwortung einer zentralen Eingangsfrage an den Reifegrad des jeweiligen Unternehmens anpasst. Der zweite Abschnitt ist davon unabhängig. Alle Teilnehmenden erhalten hier dieselben Fragen.

Im Umgang mit den Ergebnissen der Befragung sind die folgenden Einschränkungen zu beachten. Durch einen flexibel gestalteten Fragebogen kann es vorkommen, dass bei der Auswertung von Teilmengen die Datengrundlage in manchen Szenarien geringer ist. In solchen Fällen wird bei der Evaluation auf die Interpretation konkreter numerischer Werte verzichtet. Stattdessen werden Trends analysiert, die sich auf Basis der vorhandenen Daten ergeben. Zum anderen bestehen in vielen Unternehmen nach wie vor Unklarheiten bezüglich der Definition von KI und ihrer Abgrenzung. Zu Beginn der Umfrage wurde deshalb eine Definition von KI vorgegeben, um den Teilnehmenden eine einheitliche Diskussionsbasis zur Verfügung zu stellen. Dennoch besteht die Möglichkeit, dass Teilnehmende ihr eigenes Verständnis von KI zugrunde gelegt haben und es somit zu leichten Unschärfen zwischen den einzelnen Rückläufern kommt.

3.2 Charakterisierung der Umfrageteilnehmenden

Insgesamt wurden 71 Personen aus Unternehmen aus dem verarbeitenden Gewerbe – von KMU bis hin zu Großunternehmen – im Zeitraum von September bis Oktober 2020 befragt. Wie in Abbildung 2 a) dargestellt, ist das Verhältnis von KMU zu großen Unternehmen ausgeglichen, wobei der Anteil an Teilnehmenden aus KMU 46,5 % an der Grundgesamtheit beträgt. Mit 67,6 % wurde ein Großteil der befragten Unternehmen bereits vor 1980 gegründet, lediglich acht Unternehmen sind seit der Jahrtausendwende entstanden.

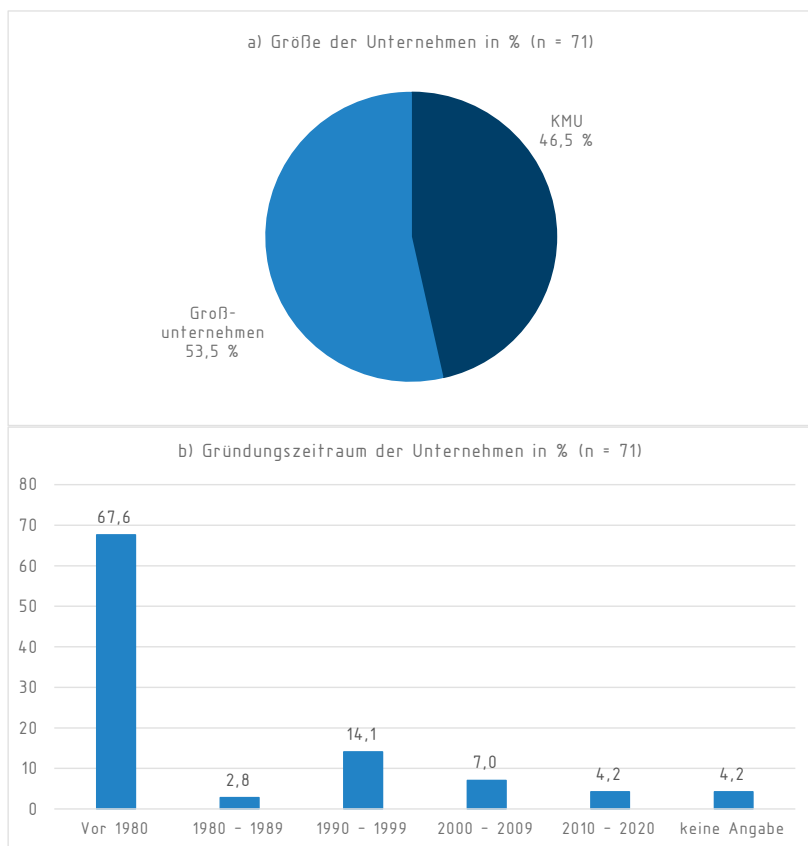


Abbildung 2: Charakterisierung der teilnehmenden Unternehmen

An der Umfrage nahmen Personen aus Unternehmen mit heterogenen Tätigkeitsschwerpunkten teil. Demnach wird anhand der Rückmeldungen ein weiterer Bereich des verarbeitenden Gewerbes abgedeckt. Wie in Abbildung 3 a) zu erkennen, sind Unternehmen aus der Automobilbranche und Luftfahrt mit einem Anteil von 19,7 % am stärksten vertreten, gefolgt von dem Maschinenbau und der Elektroindustrie. Die im Bereich „Andere“ zusammengefassten Unternehmen sind als Vertretung ihrer Branche jeweils nur einmal vorhanden und reichen von reinen Dienstleistungsanbietern bis hin zu Energieversorgern.

Die befragten Personen selbst agieren nicht nur in primären, sondern auch in unterstützenden Unternehmensbereichen. In Abbildung 3 b) ist zu erkennen, dass die Bereiche Produktentwicklung, Produktion und Geschäftsleitung am häufigsten genannt wurden und die Teilnehmenden aus diesen Tätigkeitsfeldern insgesamt 70 % der Grundgesamtheit entsprechen. Dabei reicht die Bandbreite an Funktionen der Personen von Angestellten mit und ohne Führungsverantwortung, über die Abteilungsleitung bis hin zur Geschäftsführung.

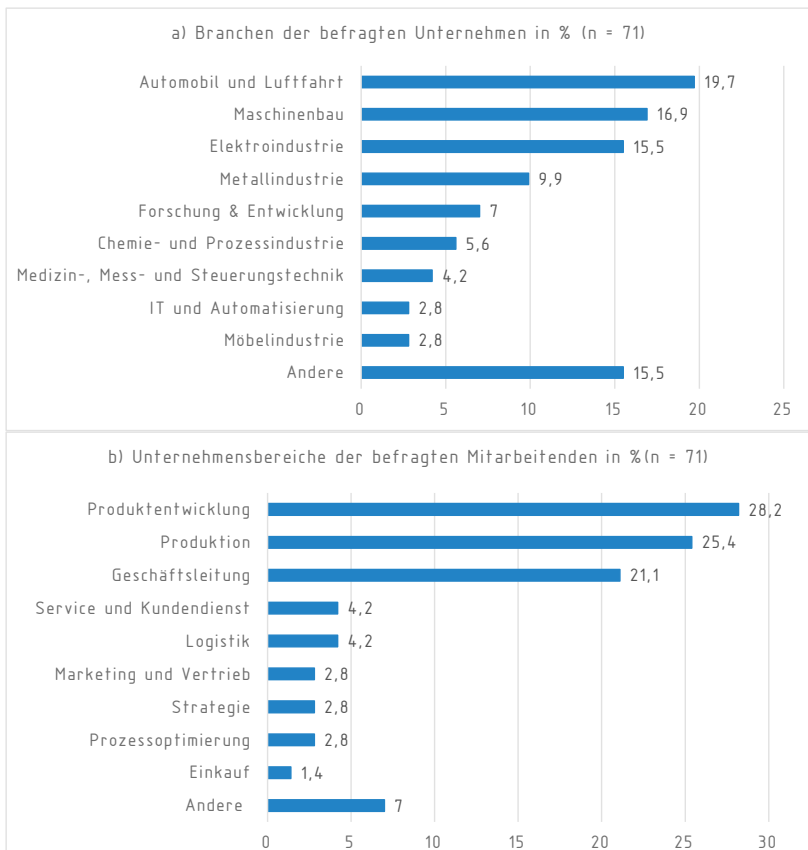


Abbildung 3: Unternehmensbranchen und Unternehmensbereiche

3.3 Ergebnisse der Expertenbefragung

Gegenstand des folgenden Abschnittes sind die Ergebnisse der quantitativen Auswertung der Expertenbefragung. Die Auswertung erfolgt in sechs Teilabschnitten, welche sich an den in Abschnitt 3.1 vorgestellten Hypothesen zur Umfragerstellung orientieren. Das Ziel ist es herauszuarbeiten, in welchem Umfang und für welche Anwendungsszenarien bereits heute KI im verarbeitenden Gewerbe eingesetzt wird. Anschließend werden die Gründe analysiert, welche die Einführung der vorgestellten KI-Anwendungen initiiert haben. Darauf aufbauend wird das Potenzial identifiziert, das KI für eine Effizienzsteigerung der betrachteten Ressourcen

(vgl. Abschnitt 2.2) besitzt. Der fünfte Teilabschnitt beschäftigt sich mit der Rolle von externen Partnerschaften für die Entwicklung von KI. Abgeschlossen wird die Auswertung mit einer Erarbeitung von Unterschieden zwischen KMU und Großunternehmen hinsichtlich des Einsatzes und der Durchdringung von KI. Erfolgsfaktoren und Hemmnisse für die Einführung von KI werden gesondert in Kapitel 6 diskutiert.

Einsatz und Bedeutung von KI im verarbeitenden Gewerbe

Der Anteil an Unternehmen, die bereits heute KI im Einsatz haben, gibt Aufschluss darüber, inwiefern die Technologie im verarbeitenden Gewerbe etabliert ist. Wie in Abbildung 4 a) dargestellt, geben 42,3 % der befragten Unternehmen an, bereits mindestens eine KI-Anwendung implementiert und Erfahrungswerte im Unternehmen zum Einsatz dieser aufgebaut zu haben. Die Mehrheit der Unternehmen, die bereits heute KI verwenden, will zusätzlich Anwendungsbereiche identifizieren, um in Zukunft noch mehr KI-gestützte Prozesse zu etablieren (28,2 % der Stichproben). Ein umgekehrtes Verhältnis zeigt sich bei jenen Unternehmen, die bisher keine KI eingesetzt haben. Diese zeigen sich gegenüber dem künftigen Einsatz von KI deutlich zurückhaltender. Insgesamt geben 33,8 % aller Unternehmen an, bisher keine Erfahrungen mit KI gesammelt zu haben und den Einsatz auch in Zukunft nicht zu planen.

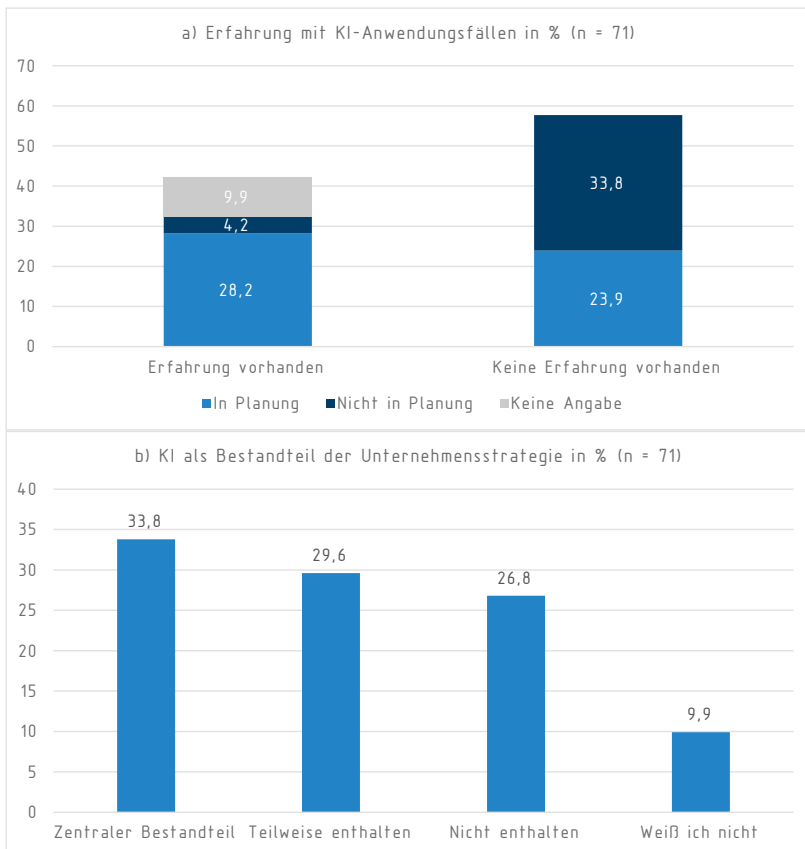


Abbildung 4: Einsatz und Bedeutung von KI

Abbildung 4 b) visualisiert die Erkenntnis, dass die Verwendung von KI bei etwa einem Drittel der Unternehmen einen wesentlichen Faktor ihres unternehmerischen Handelns sowie einen zentralen Bestandteil der Unternehmensstrategie ausmacht. Knapp 30 % der Unternehmen geben an, dass der Einsatz von KI zumindest als Teilstrategie aufgenommen und somit in der strategischen Ausrichtung verankert ist. Lediglich bei 26,8 % der befragten Unternehmen wird KI in der Unternehmensstrategie nicht berücksichtigt. Die Ergebnisse zeigen, dass der Einsatz von KI im verarbeitenden Gewerbe von großer Bedeutung ist. Etwa zwei Drittel aller Unternehmen haben dies in ihrer strategischen Unternehmensplanung verankert.

Häufig Nutzende und Anwendungen

KI-Anwendungen lassen sich Unternehmensbereichen und den daran gekoppelten Anwendungsbereichen zuordnen. Abbildung 5 a) greift die Frage auf, wo KI im Unternehmen eingesetzt wird. Befragt wurden ausschließlich Unternehmen, die KI bereits verwenden (flexibles Fragenmodell - vgl. Abschnitt 3.1). Hierbei war die Auswahl mehrerer Antworten möglich. Etwa zwei von drei Unternehmen die KI bereits nutzen, setzten diese in der Produktion ein und etwa jedes zweite in der Forschung und Entwicklung (F&E). Mit etwas Abstand folgt die Logistik. Bis auf wenige Ausnahmen im Einkauf und in der Geschäftsplanung sind alle weiteren KI-Anwendungen primären Tätigkeiten zuzuordnen. Hierbei handelt es sich nach der Definition des Ökonomen Michel E. Porter um diejenigen Tätigkeiten, die einen direkten wertschöpferischen Beitrag zur Erstellung eines Produktes oder einer Dienstleistung liefern³⁸. Die Vielfalt der Anwendungsbeispiele, in denen KI eingesetzt wird ist groß. In Abbildung 5 b) sind zehn Anwendungsbereiche aufgelistet. Mit jeweils etwa 40 % dominieren die Anwendungsbereiche Fehlererkennung und -vorhersage, Prozessoptimierung in Produktentwicklung und Produktion sowie Produktoptimierung.

Diese lassen sich den Unternehmensbereichen Produktion und F&E zuordnen, was die in Abbildung 5a) dargestellten Erkenntnisse unterstreicht. Prozessoptimierung und Prozessplanung sind Anwendungsbereiche, in denen KI unternehmensübergreifend häufig eingesetzt wird. Zur Steigerung der Ressourceneffizienz wird KI derzeit nur von 12,9 % der befragten Unternehmen verwendet. Dieser Anteil ist verhältnismäßig gering. Dennoch zeigt sich, dass in ausgewählten Umgebungen KI als eine Technologie wahrgenommen wird, mit der sich die betriebliche Ressourceneffizienz nachhaltig steigern lässt. Zudem ist festzuhalten, dass sich KI-Anwendungen, welche aus anderen Beweggründen - d. h. in anderen Anwendungsszenarien - eingeführt werden, oftmals positiv auf die Ressourceneffizienz auswirken. In einem solchen Szenario ist die Steigerung der Ressourceneffizienz ein sekundärer Effekt, welcher in der Praxis nur selten quantifiziert wird.

³⁸ Vgl. Porter, M. E. (1985).

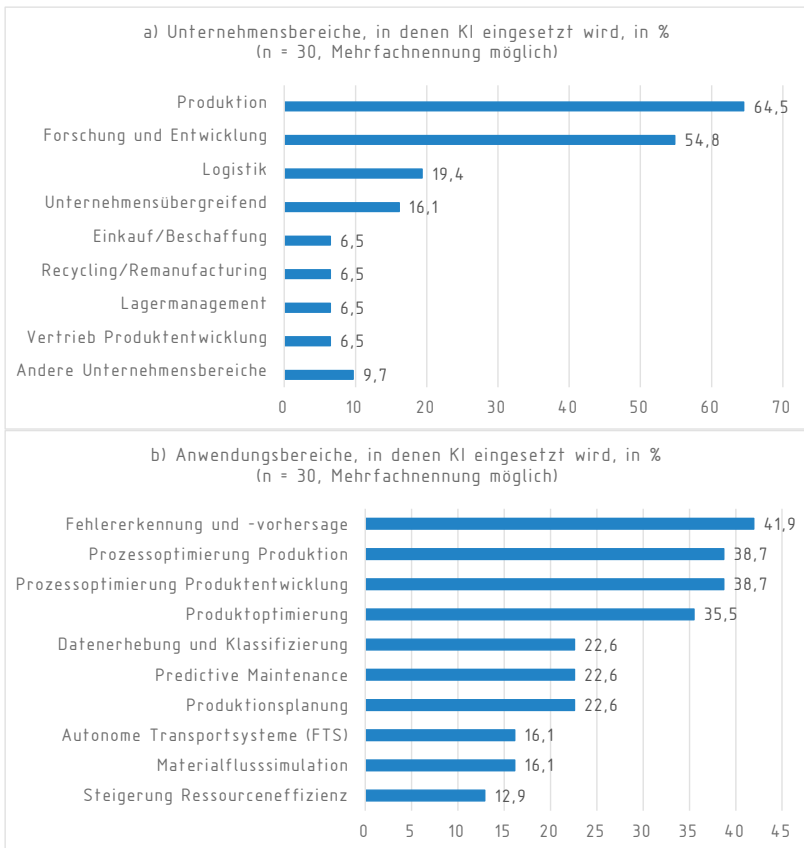


Abbildung 5: Unternehmens- und Anwendungsbereiche, in denen KI eingesetzt wird

Motivation für den Einsatz implementierter und geplanter KI

Wie im vorangegangenen Abschnitt dargestellt, setzen derzeit mehr als 40 % der befragten Unternehmen KI ein. Abbildung 6 führt Gründe auf, weshalb sich Unternehmen für den Einsatz von KI entschieden haben und warum dieser in Zukunft geplant ist. Auch hier waren Mehrfachnennungen (max. 3) möglich. Die Prozentangaben entsprechen dem Anteil an Unternehmen, für die der jeweilige Motivationsgrund entscheidend ist. Wie in Abbildung 6 visualisiert, sind Kosteneinsparungen, Qualitätsverbesserungen, Zeitersparnisse und Wettbewerbsvorteile die dominierenden Entscheidungskriterien für Unternehmen. 25,7 % der Unternehmen geben an, KI bereits für Kosteneinsparungen eingesetzt zu haben und 23 % äußern,

dies noch in Planung zu haben. Kosteneinsparungen stellen somit einen entscheidenden Faktor dar, dicht gefolgt von den Zielen der Verbesserung der Qualitätseigenschaften des Produktes und der generellen Zeiteinsparung in der Produktion. Für viele Unternehmen bietet der Einsatz von KI zudem das Potenzial, sich bei wachsendem Wettbewerbsdruck, etwa über einen Preisvorteil oder verbesserte Eigenschaften des Produktes, zu differenzieren. Zudem ergibt sich die Möglichkeit, sich wiederholende Aufgaben zu automatisieren und somit den Mitarbeitenden mehr Zeit für komplexere Haupttätigkeiten zu ermöglichen.

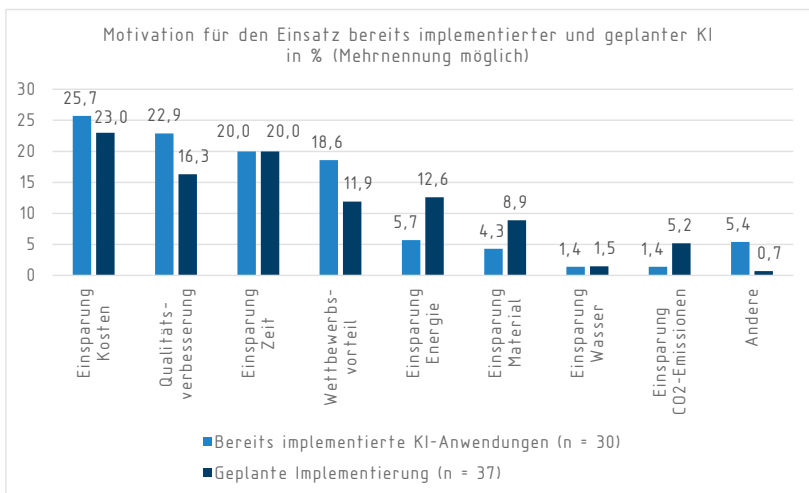


Abbildung 6: Motivation für den Einsatz bereits implementierter und geplanter KI

Bezüglich der Motivation zur betrieblichen Ressourceneinsparung von Material, Energie, Wasser und Treibhausgasen dreht sich das Bild: Eine Steigerung der Ressourceneffizienz war bei bereits implementierten Lösungen vergleichsweise selten die treibende Motivation. Die Einsparungen von Energie (5,7 %) und Material (4,3 %) sind bisher nur für wenige der Unternehmen ein Entscheidungskriterium hinsichtlich des Einsatzes von KI. Einsparungen von Wasser und THG wirken mit 1,4 % noch weit weniger entscheidungskritisch. Allerdings ist die zunehmende Relevanz der Ressourceneffizienz für Unternehmen klar zu erkennen. Bereits implementierte KI-Anwendungen in diesem Bereich liegen bei jeder Ressource erkennbar unter den Angaben für eine geplante Implementierung und lassen auf

die stark zunehmende Bedeutung von KI-Anwendungsszenarien in Bezug auf Ressourcen und den Wandel zu einem erhöhten Bedarf an Ressourceneffizienz schließen.

Einsparpotenzial von Ressourcen durch den Einsatz von KI

Wie bereits dargestellt, sind Kosteneinsparung und Qualitätsverbesserung die relevantesten Gründe zur Nutzung von KI. Dennoch spielt die Einsparung von Ressourcen – nicht nur bei der Verfolgung ökologischer Zielstellungen – in der Wahrnehmung eine wichtige Rolle.

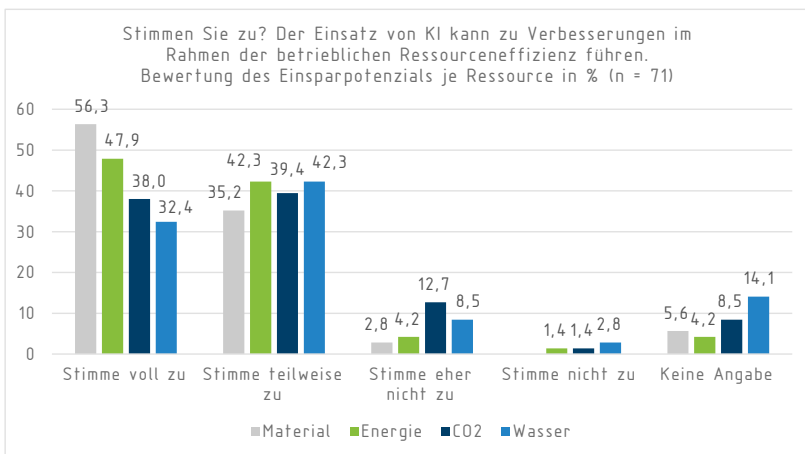


Abbildung 7: Einschätzung zur Verbesserung der Ressourceneffizienz durch KI

Abbildung 7 visualisiert das Resultat der Befragung, inwiefern KI dazu beitragen kann, die betriebliche Ressourceneffizienz zu verbessern. Dabei wurden gemäß Abschnitt 2.2 die Ressourcen Material, Energie, THG-Emissionen und Wasser nach ihrem Einsparpotenzial anhand einer Ordinalskala subjektiv bewertet. Die Teilnehmenden haben ihre Zustimmung oder Ablehnung entsprechend der These, dass KI zur Effizienzsteigerung beitragen kann, angegeben. Die betriebliche Ressource Material (56,3 %) weist dabei den höchsten Anteil bei der vollen Zustimmung der Umfrageteilnehmenden auf, gefolgt von Energie (47,9 %), THG-Emissionen (38,0 %) und Wasser (32,4 %). Diese Tendenz deckt sich mit der Kostenstruktur der Unternehmen. Charakteristisch für das verarbeitende Gewerbe ist ein hoher Verbrauch an Roh-, Hilfs- und Betriebsstoffen. Diese stellen demnach

den größten Kostenfaktor dar und entsprechen im Durchschnitt über 42 % der Gesamtkosten³⁹. Auch der Anteil an Energiekosten kann insbesondere in energieintensiven Industrien wie der chemischen Industrie oder der Stahlindustrie einen erheblichen Kostenfaktor ergeben. Dagegen fallen die Kosten für Wasser und THG-Emissionen deutlich weniger ins Gewicht. Es ist daher nicht verwunderlich, dass der Ressource Material gefolgt von Energie das größte Potenzial zur Effizienzsteigerung durch KI beigemessen wird. Insgesamt überwiegt die positive Wahrnehmung klar gegenüber der negativen. Addiert erreichen die beiden Antwortmöglichkeiten „Stimme voll zu“ und „Stimme teilweise zu“ bei allen vier Ressourcen Werte über 70 % - bei Material und Energie sogar mehr als 90 %.

Um die Frage nach der erwarteten und tatsächlichen Ressourceneinsparung beantworten zu können, ist ein Sankey-Diagramm erstellt worden (siehe Abbildung 8). Sankey-Diagramme sind graphische Darstellungen von Mengenflüssen, wobei mengenproportional dicke Pfeile genutzt werden. Im vorliegenden Sankey-Diagramm wird also gezeigt, wie sich die prozentualen Erwartungen der Ressourceneinsparungen einzelner Gruppen entwickeln und welche tatsächlichen Ressourceneinsparungen realisiert wurden. Dabei wurde anders als bei der Umfrage im Diagramm nicht nach den gemäß in Abschnitt 2.2 definierten Ressourcen Material, Energie, THG-Emissionen und Wasser unterschieden. Stattdessen wurde zur besseren Verständlichkeit die Summe der Ressourceneinsparungen aus den einzelnen Ressourcen visualisiert. Die hier dargestellten Mengenflüsse zeigen den Vergleich zwischen geschätzter erwarteter Ressourceneinsparung vor und geschätzter tatsächlicher Ressourceneinsparung nach dem Einsatz von KI im Unternehmen. Die Teilnehmenden haben die Einsparung je KI-Anwendung auf einer Intervallskala von 0 % bis hin zu mehr als 50 % bewertet und dabei zwischen dem erwarteten Effekt vor der Implementierung und dem tatsächlich realisierten Effekt unterschieden. Die Knoten repräsentieren die erwarteten bzw. tatsächlichen Einsparungen und sind nach ansteigender Größe angeordnet. Die Breite der Knoten ist ein Maß für die Häufigkeit der entsprechenden Klassen.

³⁹ Vgl. Statistisches Bundesamt (2017).

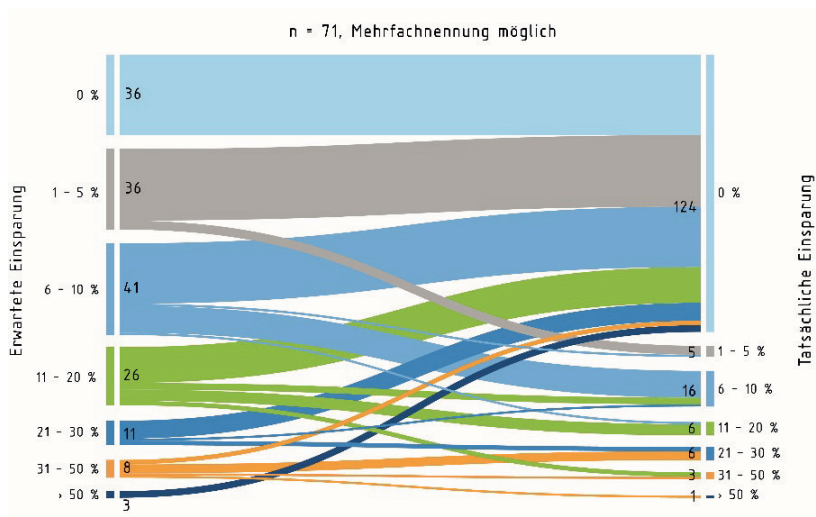


Abbildung 8: Vergleich der erwarteten Einsparung von Ressourcen gegenüber der tatsächlichen Einsparung

Ein Vergleich der Knoten auf der linken Seite zeigt, dass die erwartete Ressourceneinsparung für ein Viertel aller KI-Anwendungen zwischen 6% und 10% liegt. Die beiden Knoten mit einer erwarteten Einsparung von 1% bis 5% und 11% bis 20% folgen mit leicht geringeren Häufigkeiten dahinter. An 6% aller KI-Anwendungen ist ein Einspareffekt von 30% oder höher geknüpft. Im Vergleich dazu liegt der Anteil an KI-Anwendungen bei etwas über 20%, deren erwartete Einsparung 0% beigemessen wird. Insgesamt zeigt sich die erwartete Einsparung von Ressourcen durch den Einsatz von KI bei einem Durchschnitt von 9,9%.

Bei einer Analyse der Rückmeldungen bezüglich der tatsächlichen Einsparungen von Ressourcen ergibt sich ein deutlich geringerer Effekt. Im Durchschnitt liegt die tatsächliche Einsparung bei 3,6%. Der Durchschnitt ist deshalb so gering, da der Anteil an implementierten KI-Anwendungen, die keinerlei Auswirkungen auf die Ressourceneffizienz haben, um mehr als den Faktor drei gestiegen ist (verglichen zur erwarteten Einsparung). Eine Betrachtung der farblich markierten Ströme zeigt, dass aus jedem Knoten auf der linken Seite substantielle Anteile in den 0%-Knoten auf der rechten Seite gewandert sind. Es ist der klare Trend zu erkennen, dass die erwartete

ten Einspareffekte auf der linken Seite im Vergleich zu den tatsächlichen Einsparungen tendenziell nach unten korrigiert wurden.

Es wird deutlich, dass ein Großteil der KI-Anwendungen ihren erwarteten positiven Beitrag zur Ressourceneffizienz nicht vollständig erfüllen können. Zwei von drei Anwendungen zeigen keinen Effekt, obwohl die Erwartung an einen effizienteren Einsatz der Ressourcen an sie geknüpft war.

Die konkreten Zahlen der Einspareffekte sind allerdings mit dem Wissen zu bewerten, dass eine exakte Messung der Einsparung komplex ist und den Unternehmen oftmals nicht vorliegt. Die dargestellten Zahlenwerte entsprechen somit meist Schätzwerten. Nichtsdestotrotz ist eine Tendenz zu beobachten, dass die Erwartungshaltung gegenüber der Einsparung von betrieblichen Ressourcen größer ist als der tatsächlich eintretende Effekt.

Bedeutung externer Partner bei der Entwicklung von KI

In diesem Abschnitt wird die Frage untersucht, inwiefern Unternehmen, die sich für den Einsatz von KI entschieden haben, externe Dritte bei der Entwicklung und Implementierung mit einbeziehen. Laut Abbildung 9 a) zeigt sich, dass 40% der befragten Unternehmen KI-Lösungen eigenständig entwickeln. Entsprechend beziehen die verbleibenden 60% externe Partnerinnen und Partner mit ein. Der Grad der Zusammenarbeit unterscheidet sich dabei deutlich. Etwa zwei Drittel der Unternehmen, die auf externes Fachwissen zurückgreifen, wählen eine kooperative Entwicklung. Das restliche Drittel lagert die Entwicklung vollständig aus, indem es entweder fertige Lösungen off the shelf kauft, als Service bezieht oder ein Dienstleistungsunternehmen damit beauftragt, maßgeschneiderte Lösungen zu entwickeln.

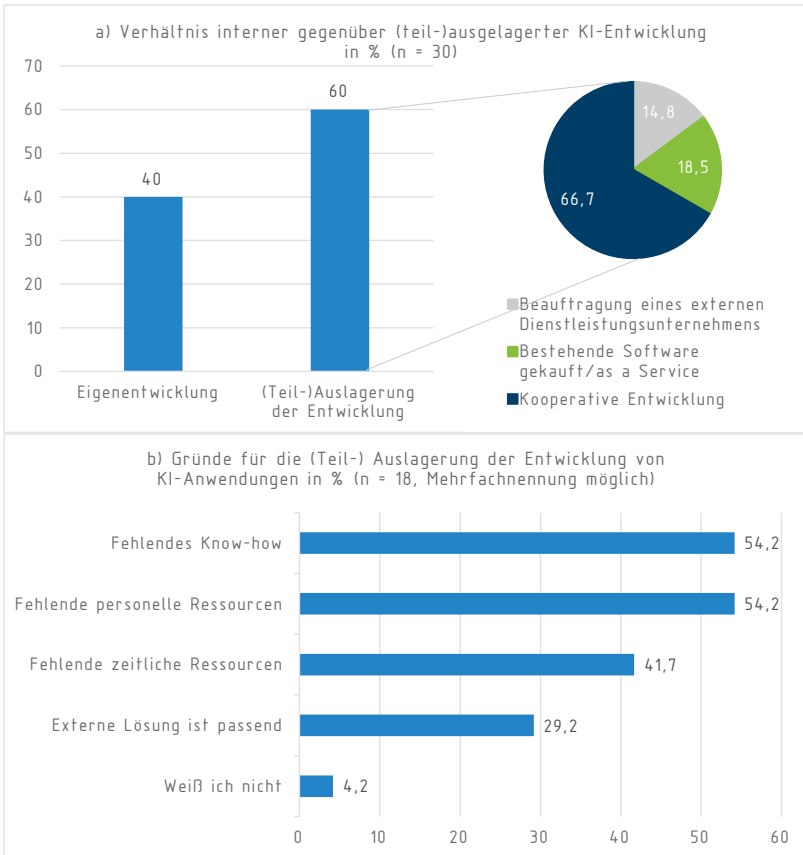


Abbildung 9: Heranziehen externer Partner bei der Entwicklung von KI

Abbildung 9 b) führt Gründe auf, weshalb sich Unternehmen für eine Zusammenarbeit mit externen Dritten entscheiden. Es ist zu beachten, dass die Teilnehmenden bei der Befragung bis zu drei Antwortmöglichkeiten angeben konnten. Die Prozentangaben lassen sich somit als der Anteil an Unternehmen interpretieren, für die der jeweilige Grund entscheidend bzw. mitentscheidend ist. Es zeigt sich, dass für etwa jedes zweite Unternehmen ein Mangel an personellen Ressourcen sowie fehlendes fachspezifisches Wissen relevante Gründe für die Zusammenarbeit mit Externen sind. Zudem geben 41,7% der befragten Unternehmen an, dass der Zeitaufwand, welcher mit der Implementierung von KI-Anwendungen einhergeht, zu groß für eine interne Entwicklung ist. In der Praxis resultiert daraus häufig

ein kooperatives Modell, bei dem Unternehmen KI-Anwendungen in Zusammenarbeit mit Externen entwickeln. Fehlende personelle Ressourcen können auf diese Weise kompensiert werden. Außerdem ermöglicht der kooperative Charakter trotzdem den nachhaltigen Aufbau von internem Expertenwissen, um nachfolgende Abhängigkeiten zu Drittparteien zu reduzieren.

Die Entwicklung geeigneter Algorithmen sowie deren Implementierung und Pflege stellen für viele Unternehmen einen Kraftakt dar. Externe Dritte spielen eine entscheidende Rolle bei dem Heranführen an neue Technologien und der Identifikation geeigneter Anwendungsbeispiele. Durch das kurzfristige Bereitstellen personeller Ressourcen und Expertenwissen unterstützen sie viele Unternehmen bei der Realisierung KI-gestützter Anwendungen.

Vergleich von KMU zu Großunternehmen

Große Unternehmen zeigen oftmals eine hohe Affinität zu neuen Technologien und sind im Vergleich zu kleinen Unternehmen Vorreiter bei deren Einführung⁴⁰. Ziel dieses Abschnittes ist es daher zu untersuchen, ob im verarbeitenden Gewerbe die Verbreitung von KI-Anwendungen in Großunternehmen weiter fortgeschritten ist als in KMU. Abbildung 10 a) zeigt sowohl für KMU als auch für Großunternehmen den Anteil der Unternehmen, die bereits mindestens eine KI-Anwendung implementiert haben. Es lässt sich ein fast identisches Verhältnis zwischen beiden Gruppen erkennen, wonach sowohl bei KMU als auch bei Großunternehmen etwa 42% aller Unternehmen bereits Erfahrungen mit KI gesammelt haben. Hinsichtlich geplanter KI-Anwendungen liegt der KMU-Anteil bei 57,6% und somit zehn Prozentpunkte über Großunternehmen. Jedoch ist zu beachten, dass 15,8% der befragten Mitarbeitenden von Großunternehmen hierzu keine Angabe vornehmen konnten. Es besteht die Möglichkeit, dass aufgrund der Größe weniger Transparenz über die Unternehmensbereiche hinweg vorhanden ist. Infolge häufig auftretender Silo-Effekte ist anzunehmen, dass Mitarbeitenden oftmals der Überblick über die eingesetzte KI in anderen

⁴⁰ Vgl. Seifert, I.; Bürger, M.; Wangler, L.; Christmann-Budian, S.; Rohde, M.; Gabriel, P. und Zinke, G. (2018).

Bereichen fehlt. Abbildung 10 c) beschreibt den Anteil an Unternehmen, die KI in ihre Strategie aufgenommen haben. Dabei wird unterschieden, ob KI ein fester Bestandteil der Unternehmensstrategie ist oder nur als Teilstrategie aufgenommen wurde. Bei etwa 40% der Großunternehmen nimmt KI einen zentralen Bestandteil der strategischen Planung ein und bei weiteren 21% ist KI als Teilstrategie implementiert wurde. Bei etwa 40% der Großunternehmen macht KI einen zentralen Bestandteil der strategischen Planung aus und bei weiteren 21% ist KI als Teilstrategie aufgenommen. Bei KMU zeichnet sich ein umgekehrtes Verhältnis ab. Bei 27,3% der Unternehmen ist KI ein zentraler Bestandteil und bei etwa 40% ist KI als Teilstrategie integriert. Werden die beiden Optionen addiert, so ergibt sich ein knapper Vorsprung für KMU hinsichtlich des Anteils an Unternehmen, die KI in ihrer Unternehmensstrategie berücksichtigen. Dass KI auch ein Treiber für die Entwicklung neuer digitaler Geschäftsmodelle sein kann, zeigt sich sowohl bei KMU als auch bei Großunternehmen deutlich.

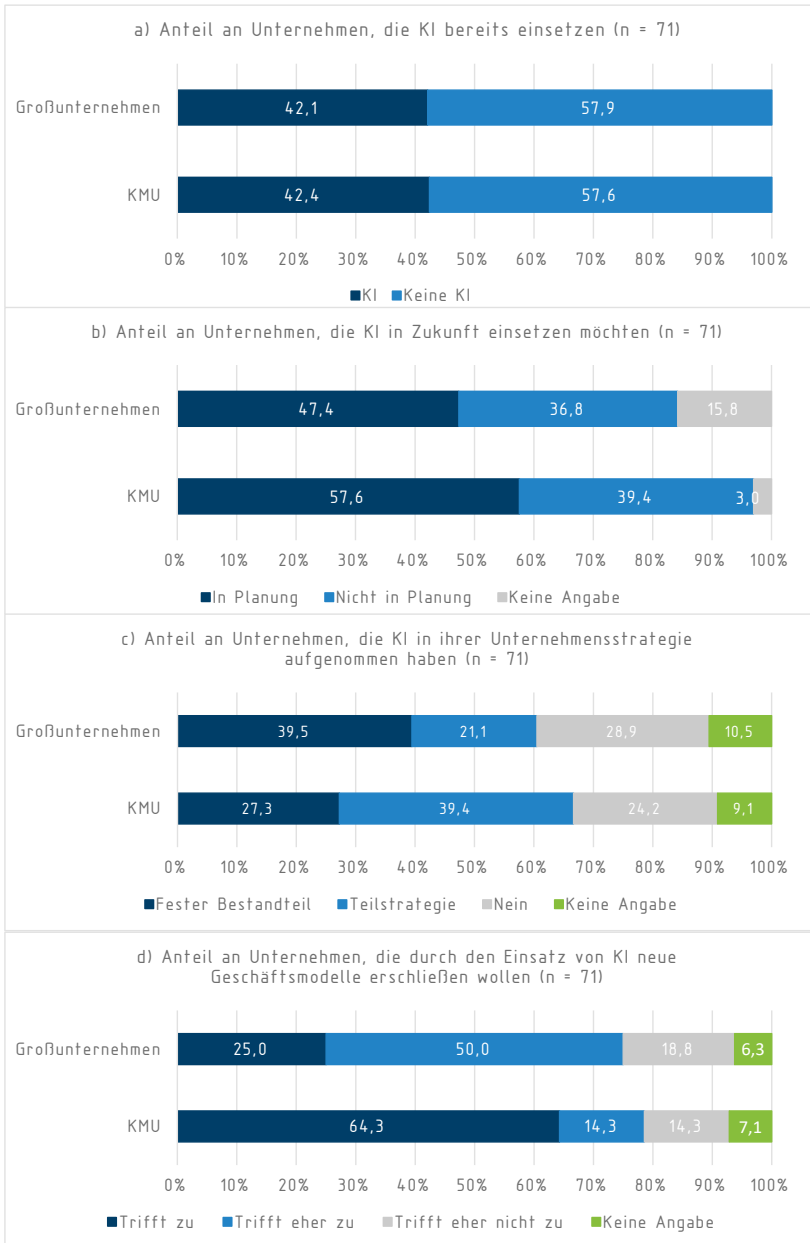


Abbildung 10: Gegenüberstellung von KMU und Großunternehmen bezogen auf den (zukünftigen) Einsatz von KI

Abbildung 10 d) stellt dar, dass zwei Drittel der befragten KMU explizit planen, durch den Einsatz von KI neue Geschäftsmodelle aufzubauen - weitere 14,3% ziehen dies in Betracht. Großunternehmen zeigen sich dagegen verhaltener in ihrer diesbezüglichen Prognose. Lediglich ein Viertel der befragten Unternehmen plant, KI-gestützte Geschäftsmodelle zu entwickeln, und weitere 50,0% halten dies für denkbar. Der Anteil, welcher das Potenzial, durch KI neue Geschäftsmodelle zu etablieren, als gering einschätzt, liegt bei KMU bei 14,3% und bei Großunternehmen mit 18,8% etwas darüber.

Insgesamt zeichnet sich ein durchweg ausgeglichenes Verhältnis zwischen KMU und Großunternehmen bezüglich des bisherigen Einsatzes von KI ab. Lediglich geringe Unterschiede sind in den Abbildung 10 a) bis d) festzuhalten. Diese illustrieren den Umfang, inwieweit KI in der strategischen Unternehmensführung berücksichtigt wird und die Erwartungshaltung, mit KI neue Geschäftsmodelle erschließen zu können.

3.4 Fazit

Die Expertenumfrage verdeutlicht, dass KI bereits in viele Bereiche der verarbeitenden Gewerbe vorgedrungen ist. 42,3 % der befragten Unternehmen nutzen schon heute KI - mit klar steigender Tendenz. Dabei ist festzuhalten, dass bezüglich des Anteils der Unternehmen, die KI anwenden, kein wesentlicher Unterschied zwischen KMU und Großunternehmen festgestellt werden konnte. Vielmehr zeigt sich ein sehr ausgeglichenes Verhältnis dadurch, dass laut den Umfragewerten die Anzahl an realisierten und geplanten KI-Anwendungen unabhängig von der Größe der Unternehmen ist. KMU erweisen sich als mutig bei der Einführung neuer KI-Anwendungen und sammeln auf diese Weise wertvolles Expertenwissen in ihrem Marktsegment.

Auf dem Weg hin zu einem sicheren und gewinnbringenden Einsatz von KI setzt die Mehrheit der Unternehmen (60 %) auf einen kooperativen Ansatz. Externe Partnerinnen und Partner spielen eine bedeutende Rolle bei der Identifikation und Umsetzung erster KI-Anwendungen von Unternehmen. Zudem ermöglichen As-a-Service-Konzepte insbesondere für KMU einen schnellen Zugang zu KI-Bausteinen. Es ist zu erwarten, dass auch in Zu-

kunft externe KI-Kompetenz eine gefragte Dienstleistung im verarbeitenden Gewerbe sein wird.

KI stellt für viele Unternehmen einen wichtigen Faktor dar, um sich gegenüber einem wachsenden Wettbewerbsdruck zu positionieren und Potenziale nachhaltig auszuschöpfen. Besonders häufig werden Methoden der KI in der Produktion oder Produktentwicklung eingesetzt – also in Bereichen, die einen direkten wertschöpfenden Beitrag zur Herstellung des Produkts oder der Dienstleistung liefern. Der Einsatz von KI ist oftmals mit dem Ziel verbunden, Kosten zu senken (25,7 %), Qualität zu verbessern (22,9 %) und Abläufe zeiteffizienter zu gestalten (20 %). Dies zeigt sich durch eine Vielzahl von Anwendungsszenarien im Bereich der Prozessplanung und -optimierung. Eine Steigerung der Ressourceneffizienz ergibt oftmals einen positiven Sekundäreffekt. Die Einsparung von Ressourcen ist jedoch nur in wenigen Anwendungen die Hauptmotivation für den Einsatz von KI (12,9 %). Dies liegt auch daran, dass Änderungen im Ressourcenverbrauch zwar wahrgenommen, jedoch nur selten quantifiziert werden.

Unternehmen sind sich der Chancen, die sich durch den Einsatz von KI ergeben, bewusst. Bereits heute haben etwa zwei Drittel aller Unternehmen KI in ihre strategische Planung integriert und somit eine starke Priorisierung eingeräumt. Das Potenzial, das durch den Einsatz von KI entsteht, um sowohl betriebliche als auch natürliche Ressourcen effizienter einzusetzen, wird als vielversprechend wahrgenommen. Je nach Ressource stimmen 80 bis 90 % der Unternehmen zu, dass der Einsatz von KI zu einer Steigerung der Ressourceneffizienz führen kann. Dies zeigt sich insbesondere beim Materialeinsatz, da dieser mit durchschnittlich über 42 % den größten Kostenanteil im verarbeitenden Gewerbe darstellt⁴¹. Vielen Unternehmen fällt es jedoch schwer, das Potenzial von KI realistisch einzuschätzen, was sich in einer großen Divergenz zwischen erwarteten und tatsächlich realisierten Einsparungen von Ressourcen zeigt.

⁴¹ Vgl. Statistisches Bundesamt (2017).

4 METHODIK ZUR POTENZIALANALYSE VON ANWENDUNGSSZENARIEN DER KI

Der Einsatz von KI bietet eine Vielzahl an Möglichkeiten, um die betriebliche Ressourceneffizienz zu steigern – sowohl aus theoretischer als auch aus praktischer Sicht. Abschnitt 4.1 beschreibt das notwendige Werkzeug, um Anwendungsszenarien der KI zu analysieren und hinsichtlich ihres Potenzials zur Erhöhung der betrieblichen Ressourceneffizienz zu bewerten. Im darauffolgenden Abschnitt 4.2 wird ein Reifegradmodell vorgestellt, welches KMU die Einordnung der eigenen Position innerhalb von sechs ausgewählten Themenfeldern mittels ihrer Potenziale ermöglicht.

4.1 Klassifikation von Anwendungsszenarien

Abbildung 11 zeigt vier Dimensionen auf, anhand derer sich Anwendungsszenarien klassifizieren und bewerten lassen.

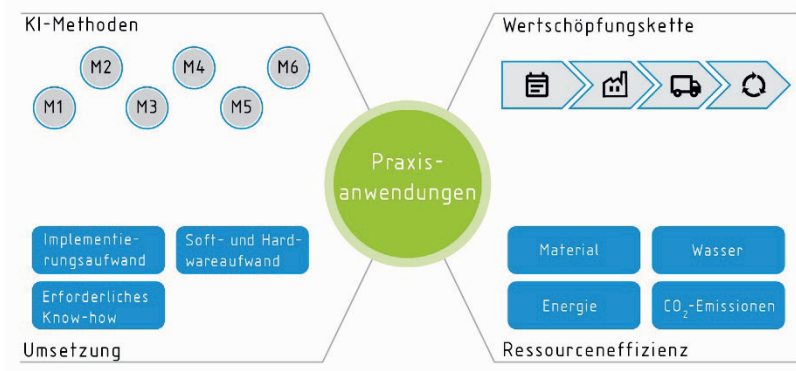


Abbildung 11: Dimensionen zur Klassifikation und Bewertung von Praxisanwendungen

Aufbauend auf Abschnitt 2.1 beschreibt die erste Dimension KI-Methoden, auf denen das Anwendungsszenario beruht. Die zweite Dimension befasst sich mit der Wertschöpfungskette der Unternehmen und legt dar, welchen Unternehmensaktivitäten das Anwendungsszenario zuzuordnen ist. Anschließend wird der Aufwand für die Umsetzung bewertet. Anhand der vierten Dimension lässt sich die Auswirkung der KI auf die betriebliche Ressourceneffizienz bestimmen. Dafür wird ein Kennzahlenmodell vorgestellt, anhand dessen sich Effizienzsteigerungen messen lassen.

4.1.1 KI-Methoden

Die in Kapitel 2.1 vorgestellten und in Anhang A vertieften Methoden der schwachen KI bilden den Grundstein jedes Anwendungsszenarios. Es handelt sich hierbei um statistische Methoden, anhand derer sich unterschiedliche Problemstellungen lösen lassen. Wichtig ist dabei zu verstehen, dass es je KI-Methodik zahlreiche Algorithmen gibt, die für eine Lösung grundsätzlich in Frage kommen. Dabei differenzieren sich die Algorithmen durch unterschiedliche Anforderungen an die Eingangsdaten, die Art und Anzahl der einstellbaren Parameter zur Steuerung der Algorithmen und die damit verbundenen Fähigkeiten zur Lösung von Zielfunktionen. Auf diese Weise lassen sich z. B. binäre Klassifikationsaufgaben anhand einfacher Entscheidungsbäume bis hin zu vielschichtigen neuronalen Netzen lösen. Die Ausgabe der Modelle ist dabei immer dieselbe, nämlich eine Einteilung des Merkmalsträgers in eine der beiden Klassen. Welche der Algorithmen die präzisesten Ergebnisse liefert, lässt sich nur schwer einschätzen. Oftmals werden mehrere Algorithmen explorativ getestet und ihre Ergebnisse miteinander verglichen.

4.1.2 Eingliederung entlang der Wertschöpfungskette

Durch die vielseitigen Möglichkeiten, KI einzusetzen, lohnt sich eine Eingliederung des zu klassifizierenden Anwendungsszenarios entlang der Wertschöpfungskette von Unternehmen. In Abbildung 12 wird ein Modell in Anlehnung an den Ökonomen Michael E. Porter vorgestellt, welches die Aktivitäten im Unternehmen in Primäraktivitäten und unterstützende Aktivitäten unterteilt⁴². Primäraktivitäten sind als solche definiert, die einen direkten wertschöpferischen Beitrag zur Erstellung eines Produktes oder einer Dienstleistung liefern. Unterstützende Aktivitäten sind dagegen solche, die für die eine erfolgreiche Durchführung von Primäraktivitäten notwendig und oftmals unternehmensübergreifend relevant sind. Praxisbeispiele lassen sich je nach Ausprägung einer oder auch mehreren solcher Unternehmensaktivitäten zuordnen. Da der Großteil der Ressourcen, insbesondere Materialien, in den Primäraktivitäten verwendet werden, liegt hierauf ein besonderer Fokus.

⁴² Vgl. Porter, M. E. (1985).



Abbildung 12: Abgrenzung von Primär- und unterstützenden Aktivitäten der Wertschöpfungskette⁴³

4.1.3 Umsetzungsaufwand

Der Umsetzungsaufwand beschreibt die personellen, zeitlichen, materiellen und immateriellen Ressourcen, die für die Inbetriebnahme und Aufrechterhaltung eines Anwendungsszenarios aufgewendet werden müssen. Die Aufrechterhaltung ist im Soft- und Hardwareaufwand sowie im Fachwissen enthalten. In Tabelle 2 sind die drei Faktoren Implementierungsaufwand, Soft- und Hardwareaufwand sowie das erforderliche Fachwissen aufgelistet, welche gemeinsam den Aufwand für die Umsetzung ausmachen. Ebenfalls sind die möglichen Ausprägungen anhand einer dreistufigen Skala definiert.

⁴³ Vgl. Porter, M. E. (1985).

Tabelle 2: Bewertungskriterien für die Umsetzung mit entsprechender Abstufung von geringem, mittlerem und hohem Aufwand

Bewertungskriterien	gering	mittel	hoch
Implementierungsaufwand	Alle personellen und zeitlichen Ressourcen sind vorhanden. Alle notwendigen Daten sind vorhanden und zugänglich.	Personelle und zeitliche Ressourcen sind nur bedingt vorhanden. Beispielsweise ist zunächst die Erhebung von umfangreichen Trainingsdaten nötig.	Der personelle und zeitliche Aufwand ist kritisch. Beispielsweise werden sehr umfangreiche Trainingsdaten benötigt wofür zunächst weitere Sensorik installiert werden muss.
Soft- und Hardwareaufwand	Einsatz von systemunabhängiger Software. Keine Integration in bestehende Systeme <u>notwendig</u>	Kleinere Eingriffe/Veränderungen in bestehenden Systemen	Umfangreiche Investitionen in anwendungsspezifische Soft- und Hardware, inkl. Integration, <u>notwendig</u> .
Erforderliches Fachwissen	Es werden kaum Vorkenntnisse benötigt. Die Systembedienung erfolgt intuitiv und / oder gibt direkte Handlungsempfehlungen aus	Es werden Fachkenntnisse benötigt, welche über den normalen Tätigkeitsbereich, z. B. die reguläre Instandhaltung, hinaus gehen.	Es werden umfassende Fachkenntnisse benötigt. Nur Spezialisten können die Methode nutzen.

Implementierungsaufwand

Der Implementierungsaufwand bezieht sich auf den zeitlichen und personellen Aufwand, der für die Einführung der entsprechenden KI-Methode benötigt wird. Ein entscheidender Faktor umfasst oftmals die Sammlung und Kennzeichnung von Daten. Dieser Prozess kann sich über einen längeren Zeitraum hinziehen. Abhängig von der benötigten Datenmenge sind gegebenenfalls neuartige Technologien - wie etwa ein Zusammenschluss von vielen Rechenkapazitäten zu Clustern - notwendig, um die Daten effizient verarbeiten zu können.

Soft- und Hardwareaufwand

Der Soft- und Hardwareaufwand bezieht sich auf die zusätzlichen Maßnahmen, die mit der Implementierung und dem Betrieb der KI-Methoden verbunden sind. Nicht immer ist hierbei eine Aufrüstung notwendig, da im Zuge der Digitalisierung schon heute Maschinen oftmals miteinander vernetzt sind und u. a. Daten zu Durchlaufzeiten oder Systemeinstellungen gesammelt werden. Hierbei kann beispielsweise die Anschaffung spezieller

Software oder die Anpassung bestehender Soft- oder Hardware in Form spezieller Sensoren notwendig sein.

Erforderliches Fachwissen

Das erforderliche Fachwissen bezieht sich auf den notwendigen methodischen und technologischen Wissenstand des Personals, das für die Implementierung und den Betrieb der Lösung verantwortlich ist. Ein hoher Aufwand entsteht vor allem durch die Breite der zum Einsatz gebrachten Technologien und die Vielfältigkeit der notwendigen KI-Methoden. Auch vorbereitende Aufgaben wie eine aufwendige Datenaufbereitung können zusätzliches Fachwissen erfordern. Letztlich kann der Betrieb einer KI-Lösung ein erweitertes Anforderungsprofil notwendig machen, da neben Kenntnissen in Statistik und Datenwissenschaft auch klassische IT-Fähigkeiten wie DevOps⁴⁴ unentbehrlich sind.

4.1.4 Kennzahlenmodell zur Messung der Ressourceneffizienz

Gemäß VDI 4800 Blatt 1 wird Ressourceneffizienz definiert als das „Verhältnis eines bestimmten Nutzens oder Ergebnisses zum dafür nötigen Ressourceneinsatz“⁴⁵. In der vorliegenden Studie werden nur die natürlichen Ressourcen Rohstoffe, Energie und Wasser sowie Ökosystemleistungen anhand der THG-Emissionen betrachtet (vgl. Abschnitt 2.2). Daraus ergeben sich zur Messung der Ressourceneffizienz die Kriterien: Steigerung der Energie-, Material- und Wassereffizienz sowie die Verringerung der THG-Emissionen.

Um die Wertbeiträge der Maßnahmen zu quantifizieren, findet sich im Folgenden eine Auswahl von Kennzahlen. Die Zieldefinition erfolgt im Hinblick auf die Erhöhung der Wertbeiträge aus der Perspektive der Verbesserung der Ressourceneffizienz. Für die nachhaltige und langfristige Verbesserung müssen die einzelnen Maßnahmen im Einklang mit der zugrundeliegenden Unternehmensstrategie stehen.

⁴⁴ DevOps setzt sich zusammen aus Entwicklung (engl. development) und IT-Betrieb (engl. IT operations) und beschreibt einen Ansatz zur Softwareentwicklung im laufenden IT-Betrieb

⁴⁵ VDI 4800 Blatt 1:2016-02.

Die Auswahl der in Tabelle 3 aufgeführten Kennzahlen erfolgt in Anlehnung an die in VDI 4801 genannten Grundsätze der Kennzahlenbildung für die Vorgehensweise zur Steigerung der Ressourceneffizienz⁴⁶. Es wird die Anwendung der gewählten Kennzahlen auf unterschiedlichen betrieblichen Bezugsebenen empfohlen, sofern sich die Kennzahlen für die unterschiedlichen Ebenen ermitteln lassen. Die empfohlenen Bezugsebenen sind daher standort-, produktions-, prozess-, anlagen- oder produktbezogen zu betrachten. Je detaillierter die Bezugsebene, desto schwieriger erscheint die präzise abgrenzbare Messbarkeit einer Systemgrenze im realen Praxisbetrieb der Unternehmen. Wenn beispielsweise nicht für jede Anlage innerhalb der Fertigung ein separater Wasserzähler installiert ist, kann folglich eine anlagen- oder prozessbezogene Bestimmung der Kennzahl „Wasserverbrauch“ nicht durchgeführt werden.

Die hier aufgeführten Kennzahlen sollen eine erste Anlehnung an die praktische Anwendung ermöglichen. Für spezifische Anwendungsszenarien sind möglicherweise weitere Kennzahlen erforderlich, um den Einfluss von künstlicher Intelligenz auf die Ressourcenverbräuche zu erfassen.

⁴⁶ Vgl. VDI 4801:2018-03.

Tabelle 3: Kennzahlensystem zur Messung der Ressourceneffizienz

Ressource	Kennzahl	Einheit	Beschreibung
Material	Materialverbrauch	kg, Liter, m ³	Unterscheidung von Materialarten sämtlicher stofflicher Inputfaktoren, inklusive Hilfs- und Betriebsstoffe.
	Verschchnitt	kg, Liter, m ³	
	Ausschuss	kg, Liter, m ³	
	Verwertbarkeit	kg, Liter, m ³	
	(Spezifische) Materialkosten	€	
Energie	Energieverbrauch	kWh, J, (l)	Energieträger in Form von Heizöl, Erdgas, Elektrizität, Fernwärme, Diesel, Benzin und Sonstige.
	(Spezifische) Energiekosten	€	
Wasser	Wasserverbrauch	m ³	
	Verwertbarkeit	m ³	
	Wasserkosten	€	
THG-Emissionen	Scope 1	kg CO ₂ e	Verbrauchsmenge und Emissionsintensität der Energieträger sowie der prozessbezogenen Emissionen
	Scope 2	kg CO ₂ e	

4.2 Reifegradmodell für Unternehmen

Beim Einsatz von KI-Methoden entstehen Anforderungen an mehrere Themenfelder im Unternehmenskontext. Das vorgeschlagene Reifegradmodell unterscheidet die Themenfelder KI-Strategie, Menschen, Prozesse, Daten sowie Technologien und Plattformen. Die Abgrenzung erfolgt im Einklang mit aktueller wissenschaftlicher Literatur und nach Rücksprache mit Experten des Fachgebiets der Datenanalyse^{47, 48, 49}.

Das vorgestellte Reifegradmodell soll KMU die Einordnung der eigenen Position innerhalb der Themenfelder anhand ihrer Potenziale ermöglichen. Die Ausprägungen der Reifegrade innerhalb der Themenfelder orientieren sich an den Anforderungen für den Einsatz von KI-Methoden. Daher ist es für den erfolgreichen Einsatz von KI-Methoden nicht zwingend erforderlich, in allen Themengebieten nach dem höchsten Reifegrad zu streben. Es werden die Ausprägungen gering, mittel, hoch und sehr hoch unterschieden.

⁴⁷ Vgl. Abdelkafi, N.; Döbel, I., Drzewiecki, J.; Meironke, A.; Niekler, A. und Ries, S. (2019).

⁴⁸ Vgl. Alsheiabni, S.; Cheung, Y. und Messom, C. (2019).

⁴⁹ Vgl. van Buren, E.; Chew, B. und Eggers, W. (2020).

Eine ausführliche Beschreibung der Ausprägungen ist im Anhang C zu finden.

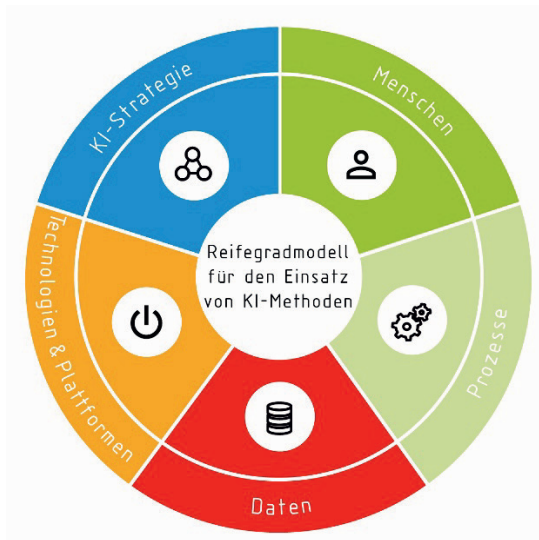


Abbildung 13: Dimensionen des Reifegradmodells

Es handelt sich bei den einzelnen KI-Methoden um transformative Technologien, wobei die Ausrichtungen und Ambitionen von entscheidender Bedeutung sind. Aus diesem Grund ist deren Ausprägung zentraler Inhalt des Themengebietes **KI-Strategie**.

Für den erfolgreichen Einsatz von KI-Methoden sind die technischen Fähigkeiten der Mitarbeitenden entscheidend. Der Zugang zu erforderlichen technischen Fähigkeiten und die Rekrutierung entsprechender Mitarbeitender stellen Herausforderungen für Unternehmen dar. Ebenso gilt es, die vorhandenen Mitarbeitenden zu schulen und Kompetenzen aufzubauen bzw. zu vertiefen. Die Entwicklung und der Einsatz von KI werden auf diese Weise unterstützt und gefördert. Das Themengebiet **Menschen** betrachtet daher die Aspekte der organisationalen Gestaltung und die Entwicklung der Talentmodelle im Unternehmen.

Prozesse sind so zu etablieren, zu definieren und zu gestalten, dass eine erfolgreiche KI-Implementierung ermöglicht wird. Obwohl KI-Piloten dazu

dienen können, das Potenzial von KI-Methoden nachzuweisen, kann ihr vollständiger Nutzen erst dann erfasst werden, wenn sie in die operativen Abläufe integriert sind. Das Themengebiet Prozesse erlaubt die Einordnung, in welchem Umfang Prozesse bereits durch KI-Methoden unterstützt und in die operativen Abläufe eingebettet sind.

Neben den technischen Kompetenzen der Mitarbeitenden, stellen **Daten** eine zentrale Grundlage für einen langfristigen und erfolgreichen Einsatz von KI-Methoden dar. Das Themengebiet Daten betrachtet daher, wie und in welchem Umfang der zielführende und strukturierte Umgang mit Daten im Unternehmen verankert ist. Ebenso sind die Art der Datenerfassung und -verknüpfung sowie die Bedeutung von Transparenz der verarbeiteten Daten und Erklärbarkeit der durch KI-Methoden ermittelten Ergebnisse zu berücksichtigen.

Zuletzt betrachtet das Themengebiet **Technologie und Plattformen**, wie KI-Methoden im Unternehmen eingesetzt werden. Je nach Anforderung der verwendeten KI-Methoden bietet sich der Einsatz von lokaler IT-Infrastruktur bis hin zu der vollständigen Anwendung in der Cloud an. Ebenso ist es von zentraler Bedeutung, wie KI-Methoden genutzt werden können. Besteht etwa ein Werkzeugkasten mit modular implementierbaren KI-Methoden, so können diese effizienter eingesetzt werden als individuell und Anwendungsszenario-spezifisch entwickelte bzw. bezogene Softwarelösungen.

Das hier vorgestellte Reifegradmodell dient zur Selbsteinschätzung und erfordert Einblicke in unterschiedliche Bereiche eines Unternehmens. Dies war aufgrund unzureichender Datenlage für keines der im folgenden Kapitel betrachteten Unternehmen möglich, weshalb die Anwendung des Reifegradmodells im Rahmen dieser Studie nicht praktisch gezeigt werden kann. Bei der Anwendung des Reifegradmodells geht es vordergründig nicht darum, den Reifegrad quantitativ in Zahlen zu ermitteln, sondern den Erkenntnisgewinn über die im eigenen Unternehmen genutzten KI-Anwendungen und ihre Auswirkung auf die betriebliche Ressourceneffizienz durch die Methodenanwendung zu erhöhen.

5 POTENZIALANALYSE AUSGEWÄHLTER ANWENDUNGSSZENARIEN

In diesem Kapitel werden Anwendungsszenarien künstlicher Intelligenz dargestellt, welche sowohl in der Literaturrecherche als auch in der Expertenbefragung eine hohe Relevanz bezüglich Ressourceneffizienz zeigen. Auf diese Anwendungsszenarien wird die in Kapitel 4 präsentierte Potenzialanalyse angewendet und durch Praxisbeispiele aus deutschen KMU untermauert.

Den Ausgangspunkt dieser Studie bildet eine umfassende Literaturrecherche (Abschnitt 2.3). Mittels dieser wurden 54 Publikationen identifiziert, welche 15 potenziellen Anwendungsszenarien zugeordnet werden können. Die durchgeführte Expertenbefragung nimmt auf diese potenziellen Anwendungsszenarien Bezug und qualifiziert sie weiter hinsichtlich ihrer praktischen Bedeutung in Unternehmen. Daraus ergeben sich acht Anwendungsszenarien mit besonderer Relevanz für die betriebliche Ressourceneffizienz.

Die Potenzialanalyse dieser acht ausgewählten Anwendungsszenarien analysiert deren technologische Umsetzung, den erforderlichen Aufwand und die Auswirkung auf die Ressourceneffizienz qualitativ und wo immer möglich auch quantitativ. Eine quantitative Bewertung des Einflusses der Einführung von schwacher künstlicher Intelligenz auf die Ressourceneffizienz ist für die Anwendungsszenarien teilweise schwierig. Dies liegt darin begründet, dass viele Anwendungen nicht maßgeblich zur Steigerung der Ressourceneffizienz eingeführt werden. Vielmehr sind es vordergründig betriebliche Faktoren, wie z. B. die Einsparung von Zeit und die Steigerung der Effizienz im Produktionsprozess, die ausschlaggebend für die Einführung der Technologie sind. Die damit verbundene Steigerung der Ressourceneffizienz wird in den seltensten Fällen direkt gemessen. Aus diesem Grund kann das beschriebene Kennzahlenmodell aus Kapitel 4.1.4 nur bedingt auf die Anwendungsszenarien angewendet werden. Der Wert der Anwendungsszenarien besteht jedoch vor allem für KMU darin, zu zeigen, wie KI in den unterschiedlichsten Branchen hilft Ressourcen einzusparen. Diese Sammlung stellt einen wertvollen Beitrag für das noch junge Feld der ressourceneffizienten KI dar. Wo eine quantitative Bewertung nicht mög-

lich war, wird daher eine qualitative Bewertung des Einflusses auf die Ressourceneffizienz gemäß Tabelle 4 vorgenommen. Hierbei ist zu beachten, dass die qualitative Bewertung der Einsparung an THG-Emissionen oftmals auf den Energie- und Materialverbrauch zurückzuführen ist. Diese sind aber nur unter der Annahme des Einsatzes von konventionellen Energieträgern (wie bspw. Kohle und Gas) direkt mit den THG-Emissionen gekoppelt, nicht jedoch bei der Verwendung regenerativer Energieträger. Informationen zum tatsächlichen Energiemix der Unternehmen in den Anwendungsszenarien liegen nicht vor, könnten jedoch Einfluss auf die vorgenommenen Bewertungen haben. Bei der qualitativen Bewertung des Einflusses auf die THG-Emissionen wird von konventionellen Energieträgern ausgegangen.

Tabelle 4: Qualitative Bewertungskriterien für die Steigerung der Ressourceneffizienz

gering	mittel	hoch
Die Steigerung der Ressourceneffizienz ist ein rein sekundärer Effekt im Anwendungsszenario. Das Ausmaß der Einsparung ist nicht signifikant bezogen auf den Gesamtprozess des Anwendungsszenarios.	Die Steigerung der Ressourceneffizienz ist ein Teilziel des Anwendungsszenarios. Das Ausmaß der Einsparung ist relevant bezogen auf den Gesamtprozess.	Die Steigerung der Ressourceneffizienz ist explizites Ziel des Anwendungsszenarios. Das Ausmaß der Einsparung ist signifikant bezogen auf den Gesamtprozess.

Generelle Aussagen zum Potenzial eines Anwendungsszenarios zur Steigerung der Ressourceneffizienz in einem Kontext außerhalb der Beispiele, lassen sich aus dieser Untersuchung nicht ableiten. Hier besteht weiterhin Forschungsbedarf, welcher die tatsächlich realisierbaren Potenziale ganzheitlich untersuchen muss.

Um die Relevanz der ausgewählten Anwendungsszenarien für KMU deutlich zu machen, beschreibt jeweils mindestens ein Praxisbeispiel deren Umsetzung. Hierbei werden die jeweiligen Herausforderungen und qualitativen Aspekte der Lösung betont und der Bezug zur Ressourceneffizienz hergestellt. Tabelle 5 zeigt eine Übersicht der ausgewählten Anwendungsszenarien und der dazugehörigen Praxisbeispiele. Die inhaltliche Beschreibung der Praxisbeispiele sowie die enthaltenen Daten wurden von den Firmen selbst mit freundlicher Genehmigung für die vorliegende Studie zur Verfügung gestellt. Es handelt sich hierbei um Stimmen direkt aus der Praxis.

Tabelle 5: Übersicht der Anwendungsszenarien und Praxisbeispiele

ID	Anwendungsszenarien	Praxisbeispiel
AS 1	Vorausschauende Wartung	LUIS Technology GmbH, LUVIS AI GmbH und Stadtreinigung Hamburg AöR - Signifikante Erhöhung der Wartungsgüte mittels Autoencoder
AS 2	Optimierung der Prozesskette	Gestalt Robotics GmbH - Optimierung der Line-Clearance durch einen digitalen Zwilling
AS 3	Optische Fehlererkennung	Werner-von-Siemens Centre for Industry and Science - Testfeld zur Förderung und Erprobung von KI-Anwendungen
AS 4	Fehlervorhersage	atlan-tec Systems GmbH - Predictive Quality in der Produktion von HDPE Rohrsystemen
AS 5	Planung der Prozesskette	Julius Zorn GmbH - Optimierung der Lagerhaltung und Produktionsplanung mittels Forecast-Algorithmen
AS 6	Produktoptimierung	IANUS Simulation GmbH - KI-gestützte Optimierung von Extrusionswerkzeugen
AS 7	Autonome Transportsysteme	Blechwarenfabrik Limburg GmbH - Prozessoptimierte Transporte durch ein intelligentes fahrerloses Transportsystem
AS 8	Sustainability Analytics	juS.TECH AG - Logistik- und Routenoptimierung

5.1 AS 1: Vorausschauende Wartung

Die Potenzialanalyse für das Anwendungsszenario der vorausschauenden Wartung wird in Abschnitt 5.1.1 am Beispiel von Fräsmaschinen durchgeführt. Das Praxisbeispiel der Kooperation aus LUIS Technology GmbH, LUVIS AI GmbH und der Stadtreinigung Hamburg AöR in Abschnitt 5.1.2 zeigt die Umsetzung des Anwendungsszenarios für eine Turbine auf einem Kehrfahrzeug.

5.1.1 Vorausschauende Wartung von Fräsen durch die Analyse akustischer Frequenzspektren

Das folgende Anwendungsszenario beschreibt den Einsatz von KI in der Fertigungslinie zur vorausschauenden Wartung von Fräsmaschinen und kann entlang der Wertschöpfungskette in der Produktion eingegliedert werden⁵⁰. Für die Potenzialanalyse des Anwendungsszenarios werden die technologische Umsetzung (Tabelle 6), die Aufwandseinschätzung (Tabelle 7) und die Potenzialabschätzung hinsichtlich Ressourceneffizienz (Tabelle

⁵⁰ Vgl. Li, H.; Wang, Y.; Zhao, P.; Zhang, X. und Zhou, P. (2015).

8) jeweils tabellarisch zusammengefasst. In diesem Anwendungsszenario wird die vorausschauende Wartung von Fräsmaschinen untersucht, die zur Bearbeitung von Stahlbauteilen eingesetzt werden. Bei diesem Vorgang nutzt sich der Schneidkopf der Fräsmaschinen kontinuierlich ab, wodurch die Schnittgenauigkeit verringert und der Ausschuss erhöht wird. Zusätzlich können der unerwartete Ausfall und die Reparatur von Maschinen den Stillstand von Fertigungsstraßen bedeuten, was zu erheblichen Kosten im Betrieb führen kann.

Tabelle 6: Technologische Umsetzung von AS 1

Faktor	Beschreibung
Hardware	Sensoren zur Detektion akustischer Frequenzspektren und Vibrationsschwingungen sowie ein Dynamometer zur Erfassung der Fräskraft
Daten	Zeitreihenanalyse akustischer Frequenzspektren der Fräse und Messung der aufgewendeten Fräskraft
KI-Methode	<p>Logistische Regression: Hierbei handelt es sich um eine nichtlineare statistische Methode, die unter anderem für die Zuverlässigkeitsanalyse und Lebensdauer- vorhersage von Maschinen eingesetzt wird.</p> <p>Dabei fungieren die akustischen Messdaten, welche Aufschluss über den Abnutzungsgrad der Maschine geben, als Eingangsvariable. Die Ausgabe des Modells kann als Wahrscheinlichkeit eines bestimmten Zustandes interpretiert werden. In dem konkreten Fall handelt es sich z. B. die Wahrscheinlichkeit, dass der Schneidkopf der Fräse aufgrund von Abnutzung ausgetauscht werden muss.</p>
Wesentliche Arbeitsschritte	<p>Wesentliche Arbeitsschritte in chronologischer Folge:</p> <ul style="list-style-type: none"> • Die Datenerhebung erfolgt an vier separaten Fräsen in unterschiedlichen Betriebseinstellungen mit jeweils neuen und gebrauchten Schneidköpfen. • Die Daten von drei Maschinen dienen als Trainingsdaten, die der vierten als Testdaten. Das akustische Signal wird anhand einer Wavelet-Transformation in mehrere Frequenzbänder zerlegt. • Vergleich der Korrelationskoeffizienten der beiden Merkmale Fräskraft und akustische Signale mit den jeweiligen Frequenzbändern. • Trainieren von zwei Modellen: Modell 1 basierend auf Daten zur Fräskraft und Frequenzspektren und Modell 2 lediglich auf Frequenzspektren. • Evaluierung der Algorithmen anhand ihrer Fähigkeit, die Restnutzungsdauer zu bestimmen. • Im durchgeführten Experiment konnten beide Modelle den Zeitpunkt, an dem der Schneidkopf ausgetauscht werden sollte (nach 40,5 min), akkurat vorhersagen, wobei Modell 1 mit 39,3 min etwas präziser war als Modell 2 mit 39,0 min. • Die Messung der Fräskraft in Echtzeit ist oftmals mit erheblichem Aufwand verbunden, weshalb Modell 2 für den Praxiseinsatz empfohlen wird.

Durch den Einsatz von KI wird der Zustand der Komponenten der Fräse überwacht und die Restnutzungsdauer bestimmt. Als Datengrundlage dienen hierbei akustische Frequenzspektren, die sich durch das Rotieren des Schneiders ergeben und in Echtzeit übermittelt werden. Mithilfe einer logistischen Regressionsanalyse werden die Frequenzspektren analysiert und mit Soll-Zustandsparametern verglichen. Die kontinuierliche Abnut-

zung des Schneiders kann damit beobachtet und die Restnutzungsdauer bestimmt werden. Überschreiten die Abweichungen einen vorher definierten kritischen Wert, so kann die Wartung der Maschine frühzeitig und zu ausgewählten Zeiten eingeleitet werden.

Tabelle 7: Aufwandseinschätzung für AS 1

Bewertungs-kriterium	Aufwand	Beschreibung
Implementierungs-aufwand	gering	Maßgeblich hierfür ist die direkte Datengewinnung an den eingesetzten Maschinen durch den Einsatz von wenigen Sensoren und die vergleichsweise geringe Anzahl an Eingangsvariablen.
Software- und Hardwareaufwand	mittel	Die zusätzlich notwendigen Sensoren sowie die Anbindung der Sensordaten an das Modell sind wesentliche Aufwandstreiber.
Erforderliches Fach-wissen	mittel	Neben der Entwicklung des logistischen Regressionsmodells ist ein technisches Verständnis zur Erhebung und insbesondere zur Interpretation gesammelter Daten der Fräse notwendig.

Für den Betrieb ergibt sich der Vorteil, dass die Planungssicherheit hinsichtlich der eingesetzten Fräsen steigt. Verschleiß kann antizipiert und das Wechseln von Schneideköpfen dahingehend geplant werden, dass Qualität und Volumen der Produktion langfristig hoch bleiben. Zusätzlich können erhebliche Kosten eingespart werden, indem ungeplante Stillstandzeiten reduziert werden. Die Auswirkungen auf die Ressourceneffizienz werden in der folgenden Tabelle dargestellt.

Tabelle 8: Qualitative Potenzialabschätzung von AS 1 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell

Ressource	Einfluss	Kennzahlen & Beschreibung
Material	mittel	Materialverbrauch in kg : Die Verringerungen der Ausschussmenge an Stahl durch die frühzeitige Detektion von Ungenauigkeiten und Vermeidung unerwarteter Ausfälle der Maschinen und die Senkung der damit verbundenen Anlaufprozesse lässt Einsparungen an Material im mittleren Maße erwarten.
Elektrische Energie	gering	Energieverbrauch in kWh : Durch die verringerten Ausschussraten und die Vermeidung von Anlaufprozessen bei Maschinenausfall sind Energieeinsparungen im geringen Maße zu erwarten.
Wasser	kein Einfluss	kein Einfluss
THG-Emissionen	mittel	Emission von kg CO₂e : Senkung des Ausstoßes an CO ₂ e die sich aus der Materialeinsparung an Stahl und der Verringerung der eingesetzten elektrischen Energie ergibt. Weitere sekundäre Effekte auf THG-Emissionen lassen sich aus Einsparungen in der Lieferkette ableiten. Insgesamt können somit Einsparungen im mittleren Bereich erzielt werden.
Andere Effekte		<ul style="list-style-type: none"> • Kosteneinsparung durch Verringerung von Stillstandzeiten der Fertigung • Senkung der Instandhaltungskosten • Erhöhung der Zuverlässigkeit der Maschinen

5.1.2 Praxisbeispiel AS 1: LUIS Technology GmbH, LUVIS AI GmbH & Stadtreinigung Hamburg AöR

Signifikante Erhöhung der Wartungsgüte mittels Autoencoder

Vorstellung der LUIS Technology GmbH, LUVIS AI GmbH & Stadtreinigung Hamburg AöR

Seit der Gründung 1999 entwickelt sich LUIS⁵¹ zu einem führenden Hersteller für Kamera-Monitor- und Fahrassistenz-Systeme in Europa. Bekannt ist LUIS vor allem für den eigenentwickelten Abbiegeassistenten. Um sich verstärkt im Bereich intelligenter Systeme zu engagieren, beteiligt sich LUIS an der 2020 gegründeten LUVIS AI GmbH⁵². Mit LUVIS AI werden Produk-



⁵¹ Vgl. LUIS Technology GmbH (2021).

⁵² Vgl. LUVIS AI GmbH (2021).

te - vor allem in den Bereichen „Embedded Vision“ und „Predictive Maintenance“ - entwickelt.

Dritter beteiligter Partner in diesem Praxisbeispiel ist die Stadtreinigung Hamburg AöR⁵³. Die Stadtreinigung Hamburg versteht sich selbst als innovatives Unternehmen und ist stets auf der Suche nach neuen Ideen, um ihre Ziele umzusetzen. Bestes Beispiel hierfür ist das folgend vorgestellte Kooperationsprojekt, in welchem die Turbine eines Kehrfahrzeugs über einen auf dem Gehäuse verbauten Beschleunigungssensor überwacht wird.

Herausforderungen des Kunden

Durch den täglichen Einsatz der Großkehrmaschinen im Zweischichtbetrieb werden die Turbinen durch Fremdkörper und die Witterung stark verunreinigt und beschädigt. Aus diesem Grund war es das Ziel, ein Monitoring-System einzuführen, welches kontinuierlich den Turbinenzustand erfasst und frühzeitige Warnsignale erzeugt. Diese sollten wiederum optisch sowie akustisch dargestellt werden. Auf diese Weise sollen frühzeitig Unwuchten erkannt werden, sodass sie - je nach Verursachung - schnell und kostengünstig behoben werden können. Dies kann beispielsweise durch eine frühzeitige Reinigung erfolgen, die unter anderem durch eine innere Spülvorrichtung durchgeführt wird. Die Belastung der Turbinenlagerung soll dadurch auf ein Minimum reduziert werden.

Lösung durch den Einsatz von KI

Das Konzept sah den Transfer einer bereits existierenden Autoencoder⁵⁴-basierten Technik vor, die sich bei der Auswertung von akustischen Getriebe- oder Kugellager-Signalen bereits bewährt hatte. Die Daten werden lokal vorverarbeitet und per 4G-Verbindung an einen Server übertragen. Dort werden die schnelle Fourier-Transformation (FFT) und

⁵³ Vgl. Stadtreinigung Hamburg (2021).

⁵⁴ Ein Autoencoder ist ein neuronales Netz mit der Aufgabe, Eingangsinformationen zu komprimieren und im Ausgang die reduzierten Informationen wieder korrekt nachzubilden. Dabei werden die Dimensionen der Eingangsinformationen reduziert, um nur die wichtigsten oder den Durchschnitt der Informationen weiterzuleiten.

die Envelope FFT sowie einige Parameter aus dem Zeitbereich berechnet. Sobald der Autoencoder Abweichungen aus dem erwarteten Signal erkennt, erfolgt eine KI-basierte Klassifizierung anhand bekannter Störungen. Über einen dritten Schritt können kundenspezifisch einfach angelegte Signaturen weiteren Fehlern zugeordnet werden, ohne dass ein komplett neues Training der Klassifizierung oder der Autoencoder stattfinden muss.

In Bezug auf die Hardware kommt ein 32-Bit-Microcontroller zum Einsatz, der mittels eines integrierten rauscharmen und breitbandigen AD-Wandlers im Zusammenspiel mit MEMS (engl. microelectromechanical system) Beschleunigungsaufnehmern eine ausgezeichnete Digitalisierung und Signalvorverarbeitung ermöglicht. Softwareseitig werden offene Lösungen im Bereich der Datenbanken und Machine-to-Machine-Techniken verwendet. Dabei ist das oberste Ziel, die aktuellen IT-Sicherheitsstandards zu berücksichtigen. Durch optimierte Software-Algorithmen wird eine hohe Performance auf moderater Hardware gewährleistet.

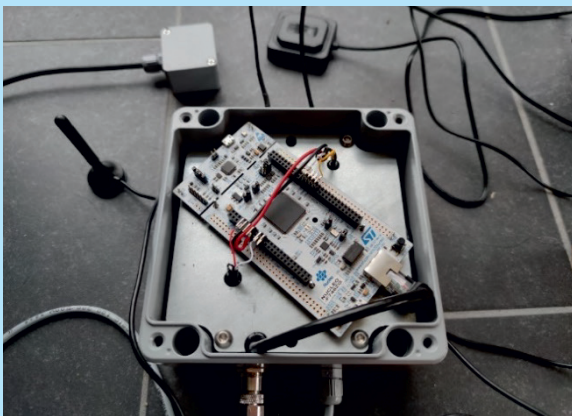


Abbildung 14: Gehäuseaufbau mit Board, MEMS-Sensor, GPS- und 4G-Antenne

Erfolgsfaktoren und Hemmnisse

Das explizite Klassifizieren von Fehlern erfordert naturgemäß das Vorliegen bekannter Fehlerzustände während des operativen Betriebs. Dies impliziert eine der Kernentwicklung nachgelagerte Projektzeit, um die vom System erkannten Fehler einzelnen technischen Defekten eindeutig zuzuordnen. Die Hard- und Softwareentwicklung wurde in diesem Fall problemlos im vorgegebenen zeitlichen Rahmen abgeschlossen. Die Eignung der eingesetzten sensiblen und sehr kosteneffizienten MEMS-basierten Beschleunigungsaufnehmer kann bislang bestätigt werden.

Ergebnisse mit besonderem Bezug zur betrieblichen Ressourceneffizienz

Die Überwachung mechanischer Komponenten, die einem gewissen Verschleiß oder möglicher Fehlbenutzung unterliegen, wird zukünftig noch stärker durch die auftretenden operativen Kosten getrieben. Der Einsatz KI-basierter Monitoring-Lösungen verhindert den unvorhergesehenen Ausfall von Komponenten und ermöglicht deren Nutzung über eine deutlich längere Betriebszeit gegenüber einer intervallbasierten Wartungsstrategie. LUIS sieht somit eine hohe Optimierbarkeit in den zeit- und kostenintensiven Wartungsprozessen. Mittels KI und der Anwendung kontinuierlicher Monitoring-Prozesse, wird die Wartungsgüte signifikant erhöht. Eine vorbeugende Wartung durch unnötigen Komponententausch mit dem einhergehenden Maschinenstillstand wird auf ein Minimum reduziert. KI-Techniken qualifizieren sich insbesondere für den Einsatz an Systemen, deren komplettes Frequenzverhalten dem Nutzer nicht bekannt ist. Das Erkennen von Wartungsproblemen muss somit keine Experteneinschätzung mehr sein.

5.2 AS 2: Optimierung der Prozesskette

Die Potenzialanalyse für das Anwendungsszenario zur Optimierung der Prozesskette wird in Abschnitt 5.2.1 am Beispiel der Energieeinsparung im Fertigungsprozess in der Wafer-Produktion dargestellt. Das Praxisbeispiel der Gestalt Robotics GmbH in Abschnitt 5.2.2 zeigt die Umsetzung des Anwendungsszenarios für die Optimierung der Line Clearance⁵⁵ durch einen digitalen Zwilling bei einem mittelständischen produzierenden Pharmaunternehmen.

5.2.1 Energieeinsparung im Fertigungsprozess in der Wafer-Produktion

Eine effiziente Energienutzung ist insbesondere in energieintensiven Industrien wie der Halbleiterindustrie von großer Bedeutung. AS 2 beschreibt die Anwendung von KI in der Fertigung, welche nach dem Gebäudemanagement die energieintensivste Einheit in Halbleiterfabriken darstellt⁵⁶. Konkret wird der Energieaufwand pro Fertigungsschritt eines Wafers gemessen. Tabelle 9 zeigt die technologische Umsetzung dieses Anwendungsszenarios im Detail.

⁵⁵ Prozess der Arbeitsplatzbereinigung von allen Produkten und Ausschussteilen, die nicht mehr für die nächste Produktion verwendet werden.

⁵⁶ Vgl. Yu, C.-M.; Kuo, C.-J. und Chung, C.-T. (2016).

Tabelle 9: Technologische Umsetzung von AS 2

Faktor	Beschreibung
Hardware	Nicht näher erläutert, keine zusätzlichen Sensoren/Hardware installiert
Daten	Die Datenerhebung erfolgt über die 48 Fertigungsschritte einer Halbleiterfabrik. Ein Fertigungsschritt ist dabei so definiert, dass er aus mehreren Maschinen bestehen kann, die denselben Arbeitsschritt ausüben. Identifikation von 19 Datenpunkten (auch Merkmalen genannt) entlang der Fertigungslinie, die sich entweder auf Lagemaße beziehen (z. B. durchschnittliche Bearbeitungszeit) oder auf Streumaße (z. B. Varianz der Bearbeitungszeit).
KI-Methode	Um den Effekt der Prozessschritte auf den Energieaufwand zu untersuchen, dienen die 19 identifizierten Merkmale als unabhängige Variablen in einer Regressionsanalyse. Dabei wird der jeweilige Einfluss der Merkmale auf die abhängige Variable, den Energieverbrauch pro Arbeitsschritt, untersucht. Für die Regression werden vier unterschiedliche Modelle verwendet, wobei der Fokus auf Neuronalen Netzen (vgl. Anhang A) liegt, die sich bei nichtlinearen Abhängigkeiten besonders eignen.
Wesentliche Arbeitsschritte	Wesentliche Arbeitsschritte in chronologischer Folge: Erhebung von Daten aus dem Fertigungsprozess über eine Zeitspanne von 120 Produktionstagen zur Untersuchung des Energieverbrauches Auswahl von vier Algorithmen, die jeweils mit fünf unterschiedlichen Parameter-Sets trainiert werden Optimierung jedes Modells dahingehend, dass der Energieverbrauch pro Arbeitsschritt gesenkt wird Evaluierung der Modelle anhand der Zielfunktion des mittleren absoluten prozentualen Fehlers Auswahl des Modells mit dem durchschnittlich geringsten mittleren absoluten prozentualen Fehler

Als Wafer werden im Fertigungsprozess die Substrate bezeichnet, auf denen elektronische Bauelemente implementiert werden. Der Fertigungsprozess der Wafer gilt als sehr komplex, wobei ein Rohling bis zu 500 Produktionsschritte zur Fertigstellung durchlaufen kann. Vor allem in der Prozessplanung ergibt sich daraus eine hohe Komplexität. Jedoch bietet die Anzahl an Schritten auch das Potenzial, fertigungsbezogene Daten in großen Mengen zu erheben, die sich für die Entwicklung entsprechender Anwendungen des maschinellen Lernens eignen. Das folgende Anwendungsszenario beschreibt, wie mithilfe von KI der Fertigungsprozess dahingehend optimiert werden kann, dass weniger Energie für die Produktion eines Wafers aufgewendet werden muss. Eine Einschätzung des hierfür notwendigen Aufwands ist in Tabelle 10 festgehalten.

Tabelle 10: Aufwandseinschätzung für AS 2

Bewertungs-kriterium	Aufwand	Beschreibung
Implementierungs-aufwand	mittel	Die verwendeten Daten wurden von 48 Produktionswerkzeugen (in diesem Fall als Gruppe von Maschinen zu verstehen, die denselben Arbeitsschritt in einer Halbleiterfertigungsfabrik durchführen) einer 8-Zoll-Wafer-Gießerei gesammelt. Die Zeitspanne der Datenerhebung umfasst 120 Produktionstage.
Software- und Hardwareaufwand	gering	Für das Trainieren der Modelle sind die Softwareanwendungen NeuroSolution 5 und STATISTICA 7 verwendet worden. Aufgrund der graphischen Oberfläche sind weitere Programmierkenntnisse nicht notwendig.
Erforderliches Fachwissen	hoch	Bei den verwendeten KI-Algorithmen handelt es sich unter anderem um komplexe neuronale Netze, deren Auswahl, Optimierung und Interpretation der Ergebnisse ein tieferes Verständnis erfordern.

Als Ergebnis des Modells wird jeweils ein Regressionskoeffizient für eines der 19 untersuchten Merkmale erhalten. Der Koeffizient gibt dabei den prozentualen positiven oder negativen Effekt auf den Energieverbrauch an, wenn das entsprechende Merkmal um 10 % verändert wird. Die Regressionskoeffizienten sind als potenzielle Stellschrauben zu verstehen, die je nach ihrem spezifischen Wert ein unterschiedlich großes Potenzial zur Energieeinsparung in der Fertigung aufweisen. Neben der Energieeinsparung haben die Maßnahmen oftmals noch andere Effekte, die möglicherweise zu einem Zielkonflikt führen können. Deshalb ist eine ganzheitliche Betrachtung der jeweiligen Maßnahmen notwendig, um mögliche andere Auswirkungen, wie beispielsweise auf den Materialverbrauch, das Produktionsvolumen oder den personellen Aufwand, zu berücksichtigen. In dem untersuchten Szenario ergibt sich ein Energieeinsparungspotenzial von bis zu 17,2%, wenn die Potenziale der 19 Merkmale addiert werden. Eine detaillierte Beschreibung des Einsparungspotenzials in Anlehnung an das Kennzahlenmodell ist in der folgenden Tabelle dargestellt.

Tabelle 11: Qualitative Potenzialabschätzung von AS 2 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodells

Ressource	Einfluss	Kennzahlen & Beschreibung
Material	kein Einfluss	
Elektrische Energie	hoch	Energieverbrauch in kWh: Die zur Wafer-Fertigung benötigte Energie beträgt 41% des Gesamtenergieverbrauchs des Unternehmens. Durch die Optimierung von Prozessschritten in der Fertigungsstraße lässt sich der Stromverbrauch um 17,2% reduzieren. Diese 17,2% sind als bemerkenswert hoch einzuschätzen, da man davon ausgeht, dass die Produktion bereits nahe am Optimum operiert.
Wasser	kein Einfluss	
THG-Emissionen	hoch	Emission von kg CO₂e: In diesem AS werden ganzheitlich alle Fertigungsschritte eines produzierenden Unternehmens betrachtet. Die damit umgesetzte Verringerung der eingesetzten elektrischen Energie geht mit Einsparungen von THG-Emissionen im gleichen Maße einher.
Andere Effekte		Bei der Optimierung der Prozesskette sind Zielkonflikte zwischen den jeweiligen Einsparungspotenzialen und dritten Faktoren wie bspw. Zeit und Qualität möglich.

5.2.2 Praxisbeispiel AS 2: Gestalt Robotics GmbH

Optimierung der Line Clearance durch einen digitalen Zwilling

Vorstellung der Gestalt Robotics GmbH

Die Gestalt Robotics GmbH⁵⁷ ist ein führender Dienstleister und Technologielieferant an der Schnittstelle zwischen klassischer industrieller Automatisierung und KI. Neben intelligenten Anwendungen der klassischen Industrierobotik und mobiler Systeme liegt ein Fokus des Unternehmens auf KI-gestützter Bildverarbeitung. Der in diesem Praxisbeispiel angesprochene Kunde ist ein mittelständisches produzierendes Pharmaunternehmen. Darüber hinaus ist ein Integrationspartner beteiligt, der auf die Konzeption und Integration neuer Produktionslinien in der Pharma-Branche spezialisiert ist.



⁵⁷ Vgl. Gestalt Robotics GmbH (2021).

Herausforderungen des Kunden

Die Herausforderungen des Kunden im vorliegenden Praxisbeispiel liegen im Bereich der sogenannten „Line Clearance“. In deren Rahmen muss die Produktion bei Produkt- oder Prozessumstellungen auf Verunreinigungen und Überreste überprüft und in einen definierten Ausgangszustand gebracht werden. Je nach Größe der Linien kann sich dieser Prozess über Stunden ziehen und wurde in der Vergangenheit nicht zielgerichtet und rein manuell ausgeführt. Der Prozess betrifft nicht nur die beteiligten Maschinen, sondern die gesamte Umgebung. In der Vergangenheit bedeutete dies einen hohen wirtschaftlichen Aufwand durch die zeitliche Belastung des Personals und Stillstandzeiten der Linie. Zudem blieben Verunreinigungen teilweise unentdeckt, was sich in der Qualität der Reinigung niederschlug. Daraus entstand die Motivation, den Prozess der Line Clearance zu teilautomatisieren, d. h. die Reinigung zielgerichteter durchzuführen. Außerdem war es das Ziel, die Prozesszeit der Line Clearance von durchschnittlich über zwei Stunden auf unter 30 Minuten zu senken.

Lösung durch den Einsatz von KI

Durch die Erstellung digitaler Zwillinge von Produktionsumgebungen können bestimmte Objektklassen oder Anomalien in der Umgebung sicher und robust erkannt und auch räumlich zugeordnet werden. Auf diese Weise lassen sich automatisiert semantische Umgebungskarten in Echtzeit erstellen und visualisieren, die auch von Menschen gelesen werden können. Im konkreten Praxisbeispiel bedeutet dies, dass Überreste automatisiert erkannt werden und der Mensch anhand einer auf einem Tablet angezeigten Karte zielgerichtet zur Beseitigung angewiesen und koordiniert wird.

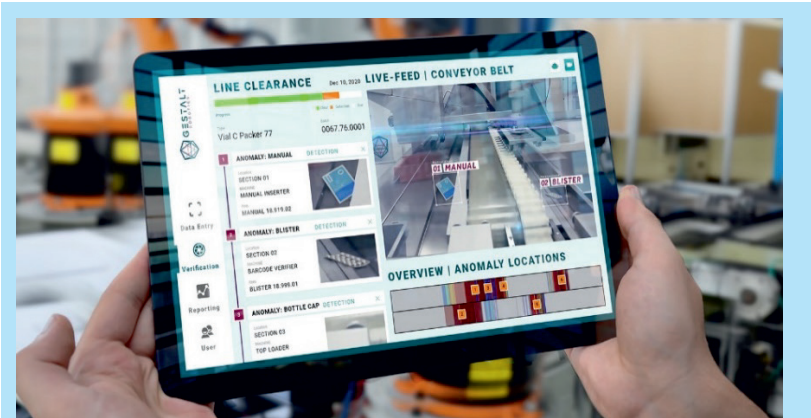


Abbildung 15: User-Interface für die zielgerichtete Line Clearance auf einem Tablet anhand des digitalen Zwillinges der Produktionsumgebung

Die konkrete Lösung im Praxisbeispiel greift auf vorhandene Kameras in einzelnen Maschinen der Linie zurück und wird ergänzt um zusätzliche stationäre Kameras sowie einer Kamera auf einem mobilen Roboter zur Abdeckung großer Umgebungsbereiche. Zusätzlich erfolgt eine Anbindung des digitalen Zwillinges an die Liniensteuerung. Die Berechnung der KI findet im konkreten Fall direkt auf einzelnen Smart-Kameras, kann aber auch flexibel und skalierbar per Cloud- oder Edge vorgenommen werden.

Erfolgsfaktoren und Hemmnisse

Herausforderungen bei der Umsetzung der Bildanalyse und damit verbundener digitaler Zwillinge sind primär die Datenschutz-Grundverordnung(DSGVO)-Konformität und die Anpassung der Technologie an das konkrete Anwendungsszenario sowie das damit verbundene Business- bzw. Betreibermodell. Damit Letzteres gerade für KMU nicht zur Kostenfalle wird, wurde im Praxisbeispiel mit einem zweiwöchigen Proof-of-Concept-Projekt gestartet, das die Machbarkeit bewies und in dessen Rahmen konkrete Key Performance Indicators (KPIs) zur Ermittlung des Returns on Investment (ROI) ermittelt wurden. Erst im nächsten Schritt erfolgte auf Basis der konkreten Erfolgsaussicht die Umsetzung in enger Zusammenarbeit der drei Partner. Zudem besteht für KMU die Option zur Wahl flexibler Bezahlmodelle, beispielsweise Pay per Use,

die helfen, die Kostenplanung zu präzisieren und im Blick zu halten. Etablierte Technologiemodule ermöglichen den flexiblen Einsatz für Individuallösungen nach dem Baukastenprinzip, was den Einsatz eines digitalen Zwillings für KMU attraktiv macht. Weiterführend können über offenen Schnittstellen wie beispielsweise OPC UA Maschinen und Anlagensteuerungen sowie ERP-Systeme flexibel integriert werden.

Ergebnisse mit besonderem Bezug zur betrieblichen Ressourceneffizienz

Im Praxisbeispiel konnten durch Einsatz des digitalen Zwillings die Stillstandzeiten um 75 % gesenkt werden, was den Energieverbrauch, dem keine Wertschöpfung gegenübersteht, deutlich senkte. Durch die Qualitätserhöhung der Line Clearance und die damit einhergehende Reduktion von Verunreinigungen in der Linie konnte zudem der Ausschuss in der Produktion reduziert werden.

In einem weiteren Kundenprojekt wurde ein digitaler Zwilling für eine Outdoor-Logistikumgebung erstellt, der Fahrerinnen und Fahrer von Lieferfahrzeugen eine Assistenz per App ermöglicht und diese zielgerichtet zu freien Parkpositionen navigiert. Mithilfe der optimierten Zielführung ließen sich als Folge von geringeren Stauzeiten und Reduzierung überflüssiger Fahrwege Energieeinsparungen realisieren.

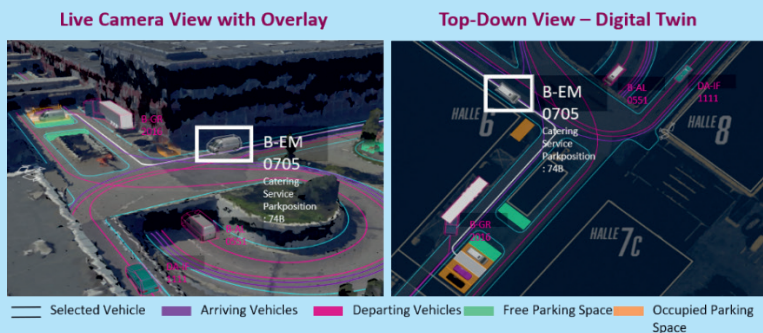


Abbildung 16: Digitaler Zwilling für eine Outdoor-Logistikumgebung

5.3 AS 3: Optische Fehlererkennung

Anwendungsszenario 3 beschreibt die optische Fehlererkennung am Beispiel der Echtzeitanalyse von Bildmaterial bei der Faserspritzgussfertigung

(Abschnitt 5.3.1). Ein Exkurs zum Werner-von-Siemens Centre for Industry and Science zeigt in Abschnitt 5.3.2 beispielhaft, wie KI-Anwendungen auch außerhalb des eigenen Unternehmens erprobt werden können.

5.3.1 Echtzeitanalyse von Bildmaterial zur Fehlererkennung in der Faserspritzgussfertigung

Aufgrund ihrer vielfältigen Materialeigenschaften gelten Faserverbundstoffe als wichtige Ressource bei der Herstellung leistungsfähiger Bauteile. Neben den Materialeigenschaften liegt ein großer Vorteil in der direkten Herstellung dreidimensionaler Formen. Als eines von zahlreichen Fertigungsverfahren kommt für die Herstellung von Faserverbundstoffen der Faserspritzguss zum Einsatz. Dieses Verfahren läuft in mehreren Schritten ab. Zunächst werden die Fasern durch eine Einströmöffnung in eine geschlossene Form geblasen. Während sich die Fasern an der Ober- und Unterform anlagern, kann die Luft durch kleine Öffnungen in den Formteilen entweichen. Sobald ausreichend Fasern in die Form gespritzt sind, wird der Rohling durch Zusammenpressen der Formen verdichtet, sodass er die Konturen von Ober- und Unterform aufweist. Anschließend sorgt ein heißer Luftstrom dafür, dass das Bindemittel schmilzt und die chemische Reaktion zum Verbundstoff stattfindet⁵⁸. Derzeit ist es noch nicht möglich, das Einspritzen der Fasern in Echtzeit zu überwachen, ohne das Verfahren stoppen zu müssen. Im Gegensatz zu anderen Formfüllungsverfahren ist es nicht möglich, eine Veränderung des Drucks und/oder der Temperatur zu messen.

Folgendes Anwendungsszenario beschreibt die Analyse von Bildmaterial zur frühzeitigen Erkennung von Fehlern während des Einspritzverfahrens⁵⁹. Tabelle 12 zeigt eine detaillierte Übersicht der technologischen Umsetzung dieses Anwendungsszenarios.

⁵⁸ Vgl. Förster, E. (30. Mai 2003).

⁵⁹ Vgl. Moll, P.; Schäfer, A.; Coutandin, S. und Fleischer, J. (2019).

Tabelle 12: Technologische Umsetzung von AS 3

Faktor	Beschreibung
Hardware	Industriekamera mit folgenden Spezifikationen: Bildrate von 20 Bildern pro Sekunde, Auflösung von 200 dpi, Sichtfeld von 400 × 400 mm. Zusätzlich werden LED-Streifen für eine homogene Ausleuchtung des Hintergrunds verwendet.
Daten	Zur Generierung von Trainings- und Testdaten werden mehrere Sequenzen von Spritzgussanwendungen aufgenommen. Insgesamt werden 484 Bilder ausgewählt und manuell gekennzeichnet.
KI-Methode	<p>Ein wesentlicher Schritt in dem Anwendungsszenario ist die automatische Erkennung von Fasern. Dafür werden Schwellenwerte definiert, die sich für die Segmentierung von Elementen auf digitalen Bildern eignen. Konkret sollen Bereiche, auf denen Fasern bereits aufgetragen wurden, von freien Flächen abgegrenzt werden. Damit lassen sich der Fortschritt des Spritzvorganges und die Schichtdicke der Fasern in Echtzeit abbilden. Folgende drei Verfahren der Segmentierung werden getestet und miteinander verglichen:</p> <p>Otsu Thresholding: Otsu Thresholding ist ein spezielles Verfahren der Segmentierung in der Bildverarbeitung und -analyse. Die Segmentierung baut auf einer Analyse von Graustufen und der anschließenden Berechnung von Unterschiedswerten auf Pixelebene auf.</p> <p>k-Means-Algorithmus: k-Means ist ein häufig verwendetes Verfahren, um Objekte in eine vordefinierte Anzahl an Clustern zu gruppieren. Die Zuordnung erfolgt auf Basis des Abstands der Objekte zu ihrem nächsten Cluster im mehrdimensionalen Raum.</p> <p>Convolutional Neural Network (CNN): CNNs beruhen auf einer Deep-Learning-Architektur und sind in der Lage, Input in Form einer Matrix zu verarbeiten. Daher ist das CNN-Verfahren besonders geeignet für die Bildanalyse. Bei der Modellentwicklung wurde eine U-Net-Architektur eingesetzt, welche sich für Segmentierungsaufgaben besonders eignet.</p>
Wesentliche Arbeitsschritte	<p>Wesentliche Arbeitsschritte in chronologischer Reihenfolge:</p> <ul style="list-style-type: none"> • Installation der Kamera und Ausrichtung der Beleuchtung von der gegenüberliegenden Seite • Generierung von Trainings- und Testdaten durch Aufnahme und manuelle Kennzeichnung von 484 Bildern aus dem Spritzgussverfahren • Vorverarbeitung der Bildaufnahmen, um die Bildgröße anzupassen und Farbabweichungen zu reduzieren • Test von drei unterschiedlichen Methoden (Otsu Thresholding, k-Means und CNN) zur Erkennung der Faserfront • Evaluation der drei KI-Modelle anhand der Anzahl korrekt vorhergesagter Pixel von 100 Testbildern, welche manuell gekennzeichnet wurden • Das Otsu-Thresholding-Verfahren und der k-Means-Algorithmus zeigen sehr geringe Fehlerraten mit 1,40 % bzw. 1,6 % auf. Die Fehlerrate des CNN ist dagegen um den Faktor zwei höher und liegt bei 3,01 %. • Erfassung der Segmentierungslinie mit OpenCV zur Visualisierung der Faserfront • Übertragung der Faserfront auf einen Monitor in der Fertigung zur Begutachtung durch Fachkräfte

Der Aufwand für die Implementierung von AS 3 liegt im mittleren Bereich. Um Trainings- und Testdaten zu generieren, ist ein vergleichsweise geringer Aufwand nötig. Eine differenzierte Betrachtung des Aufwandes findet sich in der folgenden Tabelle.

Tabelle 13: Aufwandseinschätzung für AS 3

Bewertungs-kriterium	Aufwand	Beschreibung
Implementierungs-aufwand	mittel	Integration der Kamera erfordert mögliche Um- oder Neukonstruktion der Unterform.
Software- und Hardwareaufwand	mittel	Entwicklung der KI-Methoden in der Programmiersprache Python auf Grundlage von Open-Source-Paketen. Mithilfe des frei zugänglichen findContours-Algorithmus der OpenCV-Bibliothek wird die Segmentierungslinie auf den Bildern eingezeichnet. Für die Bildaufnahme ist eine Industriekamera inklusive LED-Leuchten notwendig.
Erforderliches Fachwissen	mittel	Die Open-Source-Software ist gut dokumentiert, Kenntnisse in Python und C++ sind erforderlich.

Durch die Auswertung des Bildmaterials kann die Faserfront während des Einspritzverfahrens visualisiert und überwacht werden. Daraus ergibt sich der Vorteil, dass Ungleichheiten in der Faserverteilung frühzeitig erkannt und noch während des Prozesses korrigiert werden können. Zusätzlich können Bildaufnahmen am Ende des Einspritzverfahrens durch einen Abgleich mit Referenzbildern zur automatischen Qualitätskontrolle verwendet werden. Die sich daraus ergebenden Effekte auf den Materialverbrauch und den Prozess der Qualitätskontrolle sind in der folgenden Tabelle aufgeführt.

Tabelle 14: Qualitative Potenzialabschätzung von AS 3 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell

Ressource	Einfluss	Kennzahlen & Beschreibung
Material	gering	Materialverbrauch in kg: Durch Erkennen von Ungleichverteilungen und das Ausbessern noch während des Spritzvorganges lässt sich der Ausschuss fehlerhaft produzierter Formteile reduzieren. Dies führt unmittelbar zu einem geringeren Materialverbrauch an Faserverbundstoffen in der Produktion. Je nach Ausschussquote und deren prozentualen Veränderung sind durch die Echtzeitanalyse Einsparungen im geringen Maße zu erwarten.
Elektrische Energie	gering	Energieverbrauch in kWh: Die Verringerung der Ausschussmenge ist mit kürzeren Maschinenlaufzeiten verbunden. Damit lässt sich der geschätzte Energieverbrauch im geringen Maße verringern.
Wasser	kein Einfluss	
THG-Emissionen	gering	Emission von kg CO₂e: Senkung des Ausstoßes an CO ₂ e die sich aus der Materialeinsparung an Faserverbundstoffen und der Verringerung der eingesetzten elektrischen Energie gibt. Weitere sekundäre Effekte auf THG-Emissionen lassen sich aus Einsparungen in der Lieferkette ableiten. Insgesamt können somit Einsparungen im geringen Bereich erzielt werden.
Andere Effekte		<ul style="list-style-type: none"> Steigerung der Qualität der produzierten Formteile Senkung der Kosten in der Qualitätssicherung durch einen höheren Automatisierungsgrad

5.3.2 Exkurs: Werner-von-Siemens Centre for Industry and Science

Testfeld zur Förderung und Erprobung von KI-Anwendungen

Vorstellung Werner-von-Siemens Centre for Industry and Science

Das Werner-von-Siemens Centre for Industry & Science e.V. (WvSC) ist Teil des Berliner Zukunftsorts



Werner-von-Siemens Centre
for Industry and Science

Siemensstadt 2.0 und fokussiert sich auf eine dynamische, gemeinsame Forschung am Ort der Wertschöpfung. Ein offenes Ökosystem mit neuen Arbeitsmethoden bildet das Fundament des Vereins. Der geplante Co-Working und Co-Creation-Bereich inklusive Fertigungs- und Laborflächen zur Erstellung von Prototypen ermöglicht eine gemeinsame Forschung von Wissenschaftseinrichtungen, Universitäten, Industrie, KMU und Start-ups. Durch kurze Wege werden Begegnung und schnelles Testen von Ideen möglich. So finden eine innovative Forschung & Entwicklung (F&E) sowie beschleunigte Produkt- und Technologieentwick-

lung ohne Transferkosten statt.⁶⁰

Der Verein wird im Rahmen der Gemeinschaftsaufgabe „Verbesserung der regionalen Wirtschaftsstruktur“ mit Bundes- und Landesmitteln gefördert. Die laufenden Projekte werden durch den Europäischen Fonds für regionale Entwicklung kofinanziert.

Schwerpunkte der Forschungsprojekte sowie Ziele des WvSC

Das WvSC ist ein gemeinnütziger Verein, der gemäß seiner Satzung die Zukunftsthemen produktionstechnischer Wandel, Mobilitäts- und Energiewandel fokussiert. Dabei kommen aktuell die Querschnittstechnologien „Additive Fertigung“, „Neue Materialien“ und „Digitalisierung“ in ihren verschiedenen Facetten zum Einsatz. Die Ergänzung um weitere Technologiefelder wie beispielsweise „Connectivity/5G“ ist geplant.

Seit Sommer 2020 laufen die ersten Forschungsprojekte unter dem Dach des WvSC in den Anwendungsfeldern „Elektrische Antriebstechnik“, „Hochtemperaturanwendungen“ und „Maintenance, Repair & Overhaul“.

Im Bereich der additiven Fertigung soll künstliche Intelligenz für einen automatisierten Design-Support zur Anwendung kommen. Außerdem soll KI bei Reparaturprozessen für eine bessere Qualität sorgen, indem sie die sonst statische Reparaturkette in eine dynamische und prozessbegleitende Kette umwandelt. Dabei sollen Inspektionen individuell, digital und automatisiert vom digitalen Entscheidungsträger geleitet werden.

Die Ziele des WvSC liegen in der Förderung der Wissenschaft, Bildung und Forschung sowie in der Erneuerung der Industrie. Der Verein fördert den vorwettbewerblichen Wissensaustausch zwischen diesen Bereichen, um neue Technologiefelder und Zukunftsthemen zu erschließen und Innovationen zu beschleunigen. Die Erkenntnisse werden so aufgearbeitet, dass die Allgemeinheit darüber informiert werden kann. Vorrangiges Ziel ist die Stärkung des Standortes Berlin.

⁶⁰ Vgl. Werner-von-Siemens Centre for Industry and Science e.V. (2021).

Vorteile eines regionalen Technologie-Hubs und wie KMU davon profitieren können

Mithilfe des WvSC erhalten KMU erleichterten Zugang zu Forschungsprojekten. Die Beantragung von Forschungsmitteln setzt viel Erfahrung mit Forschungsprogrammen voraus – diese Erfahrung ist in KMU oft nicht vorhanden. Das WvSC vernetzt seine Mitglieder aktiv und themenspezifisch. Es bringt die Ideen der KMU mit den Wissensträgern für die Abwicklung von Forschungsprojekten in den Wissenschaftseinrichtungen zusammen.

Praxisbeispiel

In den Forschungsprojekten des WvSC werden aktuell Lösungen mit KI entwickelt. Es werden unter anderem Data-Pipelines zur Vernetzung elektrischer Anlagen und zum Auslesen der Betriebsparameter in einer Cloud-Architektur konzipiert. Es soll eine Datenbasis verfügbar gemacht werden, damit KI-Algorithmen trainiert werden können.

An vielen Stellen in der Wertschöpfungskette muss allerdings erst die Voraussetzung ausreichender Daten geschaffen werden, mit denen eine künstliche Intelligenz trainiert werden kann. Das Mitgliedsunternehmen 5thIndustry GmbH hat diesbezüglich ein Projekt mit der Siemens AG umgesetzt: Daten, die im Produktionsprozess anfallen (z. B. Seriennummern), werden nicht mehr auf Papier, sondern in einer App erfasst. Erst durch die konsequente Digitalisierung von Prozessschritten und Produktdaten wird häufig der Einsatz von (schwacher) KI möglich.

5.4 AS 4: Fehlervorhersage (Predictive Quality)

Anwendungsszenario 4 beschreibt die Fehlervorhersage (Predictive Quality) am Beispiel der Umformung von Blechzuschnitten zu Karosserieteilen (Abschnitt 5.4.1). Das Praxisbeispiel der atlan-tec Systems GmbH zeigt in Abschnitt 5.4.2 die Umsetzung bei der Produktion von HDPE-Rohrsystemen.

5.4.1 Fehlervorhersage bei der Umformung von Blechzuschnitten zu Karosserieteilen

Ein weit verbreitetes Verfahren zur Herstellung von Karosserieteilen für die Automobilindustrie ist das Tiefziehen. Dabei wird ein ebener Blechzuschnitt in eine Matrize eingespannt und mithilfe eines Stempels umgeformt. Da die Qualitätsanforderungen für Karosserieteile sehr hoch sind, können schon geringe Oberflächenbeschädigungen zu hohem Nachbearbeitungsaufwand oder Ausschuss führen. Während des Tiefziehens kann sich eine solche Beschädigung auch negativ auf den Zustand der Matrize und des Stempels auswirken. Ein Austausch der entsprechenden Komponenten ist in einem solchen Szenario oftmals alternativlos, was zu zusätzlichen Kosten in der Wartung führt und den Stillstand der Fertigungslinie bedeutet. Das Umformen der Blechzuschnitte bildet den zweiten von insgesamt sechs Arbeitsschritten vor der Qualitätskontrolle. Fehlerhafte Zwischenprodukte, die sich durch das Tiefziehen ergeben, nehmen deshalb zusätzliche Ressourcen in der Produktionskette in Anspruch, bevor sie aussortiert werden. Die Qualitätsprüfung der Karosserieteile erfolgt in modernen Anlagen teilautomatisiert, eine finale Betrachtung durch eine Fachkraft ist jedoch erforderlich.

Das folgende Anwendungsszenario beschreibt den Einsatz neuronaler Netze zur Vorhersage von Oberflächenbeschädigungen noch während des Tiefziehens⁶¹. Dies macht es möglich, Systemeinstellungen in Echtzeit anzupassen, damit die Beschädigung erst gar nicht auftritt. Die für die technologische Umsetzung notwendigen Faktoren werden in Tabelle 15 aufgeführt.

⁶¹ Vgl. Meyes, R.; Donauer, J.; Schmeing, A. und Meisen, T. (2019).

Tabelle 15: Technologische Umsetzung von AS 4

Faktor	Beschreibung
Hardware	Für die Durchführung von Spannungsanalysen werden Dehnungsmessstreifen angebracht, die über die Veränderung des elektrischen Widerstandes im Dehnungsstreifen die Dehnung des Bleches aufzeichnen. Die Befestigung der Dehnungsmessstreifen erfolgt an der Halterung für die Bleche. Zusätzlich werden mehrere Lasersensoren zur Abstandsmessung angebracht.
Daten	Für das Trainieren des Algorithmus werden Zeitreihendaten von mehr als 4.000 Durchläufen des Tiefziehens aus der Produktion gesammelt. Die elektrische Spannung während der Umformung des Bleches und die Laser-Abstandsmessung zum Blech dienen als Eingangsdaten.
KI-Methode	Recurrent Neural Networks (RNN): Im Gegensatz zur vorwärts gerichteten Informationsverarbeitung in klassischen neuronalen Netzen weisen RNNs Rückkopplungsmechanismen auf. Diese ermöglichen einen Informationsaustausch mit Neuronen der gleichen und vorangegangenen Schichten. Daraus ergibt sich die Fähigkeit, Informationen in ihrem zeitlichen Kontext zu berücksichtigen, weshalb RNNs besonders für die Bearbeitung von Zeitreihendaten geeignet sind.
Wesentliche Arbeitsschritte	<p>Wesentliche Arbeitsschritte in chronologischer Folge:</p> <ul style="list-style-type: none"> • Datenerhebung von mehr als 4.000 Durchläufen des Tiefziehverfahrens • Aufbereitung der Daten wie etwa das Löschen von Zeitreihendaten in denen sich der Stempel nicht bewegt • Manuelle Kennzeichnung von fehlerhaften und nicht-fehlerhaften Blechen • Zufällige Aufteilung der Daten in Trainings- und Testdaten im Verhältnis 80 : 20 • Da deutlich weniger fehlerbehaftete als nichtfehlerbehaftete Datenreihen verfügbar sind, wird eine Oversampling-Methode angewendet. Dabei wird die unterrepräsentierte Gruppe an Datenreihen vervielfältigt, um ein ausgeglichenes Verhältnis der beiden Klassifikationsgruppen zu erhalten. • Das Klassifikationsmodell wird anhand einer Confusion-Matrix evaluiert. Die erreichten Werte sind 0,9427 für die True-Positive Rate und 0,9000 für die True-Negative Rate. • Der mittlere quadratische Fehler wird als Zielfunktion des Regressionsmodells verwendet und beträgt 0,039.

Um fehlerhafte Karosserieteile vorherzusagen, werden zwei ML-Modelle separat voneinander aufgebaut und in Reihe geschaltet. Das erste ist ein Klassifikationsmodell, welches vorhersagt, ob ein Blech während des Tiefziehens eine Beschädigung erfährt. Als Ergebnis werden Wahrscheinlichkeitswerte ausgegeben, anhand derer sich die Bleche klassifizieren lassen. Beim Optimieren des Klassifikationsmodells wird eine Confusion-Matrix verwendet, die den Anteil an richtig und falsch vorhergesagten fehlerhaften und nichtfehlerhaften Blechen bestimmt. Für die Produktion von Karosserieteilen ist eine hohe Trefferquote von fehlerhaften Blechen wichtig, um Beschädigungen an dem Stempel oder der Matrize zu verhindern. Es wird dafür in Kauf genommen, dass eine gewisse Anzahl an Blechen fälschlicherweise als fehlerhaft prognostiziert werden. Die damit verbundenen Kosten sind jedoch geringer als wenn ein Blech, das fehlerhaft ist, nicht als

solches erkannt wird. Wenn ein Karosserieelement als fehlerhaft prognostiziert wird, ergibt sich daraus die Frage, zu welchem Zeitpunkt des Tiefziehprozesses die Beschädigung auftreten wird. Das zweite ML-Modell, ein Regressionsmodell, baut darauf auf und prognostiziert die Zeitspanne bis zur Beschädigung in Millisekunden. Der hier dargestellte Aufwand wird in Tabelle 16 eingeschätzt.

Tabelle 16: Aufwandseinschätzung für AS 4

Bewertungskriterium	Aufwand	Beschreibung
Implementierungsaufwand	hoch	Der zeitliche Aufwand für die Erhebung der Trainings- und Testdaten dauerte elf Monate. Außerdem wurde Zeit für die Modellentwicklung und Implementierung benötigt.
Software- und Hardwareaufwand	mittel	Keine Angabe über die verwendete Software, denkbar ist eine Entwicklung der RNNs durch Open-Source-Software. Je Tiefziehanlage sind mehrere Laser sowie Dehnungsmessstreifen erforderlich, um die notwendigen Daten zu generieren.
Erforderliches Fachwissen	hoch	Die Entwicklung der RNN erfordert Programmierkenntnisse und ein tiefes Verständnis für Machine Learning, insbesondere für die Erstellung der Modell-Architektur sowie für Feature-Engineering-Aufgaben.

Ressourcen lassen sich in Predictive Quality Anwendungsbereichen nur dann effizient einsparen, wenn die Systemeinstellungen der Maschinen dahingehend geändert werden, dass die Beschädigungen erst gar nicht auftreten. Insbesondere hier liegt die Herausforderung, da die Genauigkeit der Vorhersage mit zunehmender Länge der vorherzusagenden Zeitspanne abnimmt. Für den Tiefziehprozess von Metallblechen wurde eine notwendige Zeitspanne von 1.000 Millisekunden identifiziert, die notwendig ist, um Maschineneinstellungen noch während des Vorgangs anzupassen. Die folgende Tabelle zeigt die Einsparpotenziale von Ressourcen auf, die sich durch den Einsatz von Predictive Quality ergeben.

Tabelle 17: Qualitative Potenzialabschätzung von AS 4 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell

Ressource	Einfluss	Kennzahlen & Beschreibung
Material	gering	Materialausschuss in kg: Durch die Vorhersage von fehlerhaften Blechelementen und eine umgehende Korrektur lässt sich die Ausschussrate um 94 % von 3,6 % auf 0,2 % verringern. Die hierdurch verringerte Anzahl an fehlerhaften Zwischenprodukten nimmt weniger zusätzliche Ressourcen in der Produktionskette in Anspruch und lässt somit auf einen Einfluss im geringen Maße schließen.
Elektrische Energie	gering	Energieverbrauch in kWh: Durch die Verringerung der Ausschussmenge lässt sich der Einsatz der Maschinen und somit der Energieverbrauch verringern. In Kombination mit reduzierten Stillstandzeiten der Fertigungslinie können von daher Energieeinsparungen im geringen Maße erwartet werden.
Wasser	kein Einfluss	
THG-Emissionen	gering	Emission von kg CO₂e: Senkung des Ausstoßes an CO ₂ e die sich aus der Materialeinsparung an Blechelementen und der Verringerung der eingesetzten elektrischen Energie ergibt. Weitere sekundäre Effekte auf THG-Emissionen lassen sich aus Einsparungen in der Lieferkette ableiten. Insgesamt können somit Einsparungen im geringen Bereich erzielt werden.
Andere Effekte	–	keine

5.4.2 Praxisbeispiel AS 4: atlan-tec Systems GmbH

Predictive Quality in der Produktion von HDPE-Rohrsystemen

Vorstellung der atlan-tec Systems GmbH

Die atlan-tec Systems GmbH hat sich auf den technologischen Bereich von Digitalisierung und Big Data spezialisiert. Dabei profitiert es von einer mehr als 28-jährigen Kompetenz und Fachexpertise im Umfeld internationaler Großindustrieprojekte.⁶²



Gleichzeitig wird zunehmend der wachsende Digitalisierungsbedarf im mittelständischen Sektor gesehen, den atlan-tec auf dem Weg zur digitalen Transformation begleitet. Die angebotenen Dienstleistungen setzen sich vorrangig wie folgt zusammen:

⁶² Vgl. atlan-tec Systems GmbH (2021).

- Zusammenführen von Labordaten, Qualitätsdaten, Maschinen- oder Prozessdaten aus verschiedenen Quellen oder Datenbanken,
- Verarbeiten und Analysieren dieser Daten,
- Generieren von Datenmodellen, Softsensoren, Prädiktoren, digitalen Zwillingen und Optimierungsalgorithmen,
- Entwickeln von autonom selbstoptimierenden Prozessen und deren ökonomischer Optimierung.

Herausforderungen in der Produktion

Folgendes Praxisbeispiel bezieht sich auf ein konkretes Anwendungsszenario bei der Rohrproduktion. Der Produktionsprozess ist in Abbildung 17 dargestellt.

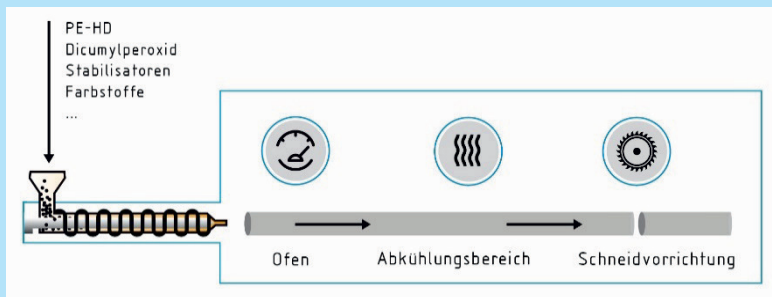


Abbildung 17: Initialer Produktionsprozess von Kunststoffrohren

Um die Vernetzungsdichte des Materials bestimmen zu können, ist eine Probeentnahme erforderlich. Da die Laboranalyse im Schnitt 24 bis 48 Stunden dauert, kann diese nur einmal täglich durchgeführt werden. Das bedeutet, dass die in dieser Zeit produzierten Rohre nicht an Kunden ausgeliefert werden können, bis ein positives Laborergebnis vorliegt. Im Falle einer fehlerhaften Vernetzungsdichte werden die Rohre nicht ausgeliefert. Das kann eine Produktion von bis zu 4.000 m Ausschuss bedeuten. Durchschnittlich führt dieser Rohrproduktionsprozess zu einer Ausschussrate von 10 % bis 20 %, die auf eine zu große Verzögerung zwischen Produktion und Qualitätskontrolle sowie eine fehlende Echtzeit-Analyse zurückzuführen ist.

Lösung durch den Einsatz von KI

Eine genaue Vorhersage der Laboranalyse kann ein sofortiges Eingreifen in den Fertigungsprozess ermöglichen und die Produktion von weiterem Ausschuss vermeiden. Dafür ist zunächst das Training eines neuronalen Netzes notwendig: Gesammelte Produktions- (Dosierungen, Temperaturen, Druckwerte, Drehmomente etc.) und Labordaten (Vernetzungsdichte des Materials) bilden die Datenbasis dafür. Diese werden in eine Datenbank eingespeist und als Trainingsset für das neuronale Netz verwendet. Die Kosten belaufen sich in diesem konkreten Szenario auf etwa 35.000 €. Anschließend wird das trainierte neuronale Netz als Prädiktor der Vernetzungsdichte in den Produktionsprozess mit aufgenommen. Der dadurch entstandene Produktionsablauf ist in Abbildung 18 dargestellt. Für die Implementierung und weitere Aufwände fallen Kosten in Höhe von etwa 25.000 € an.

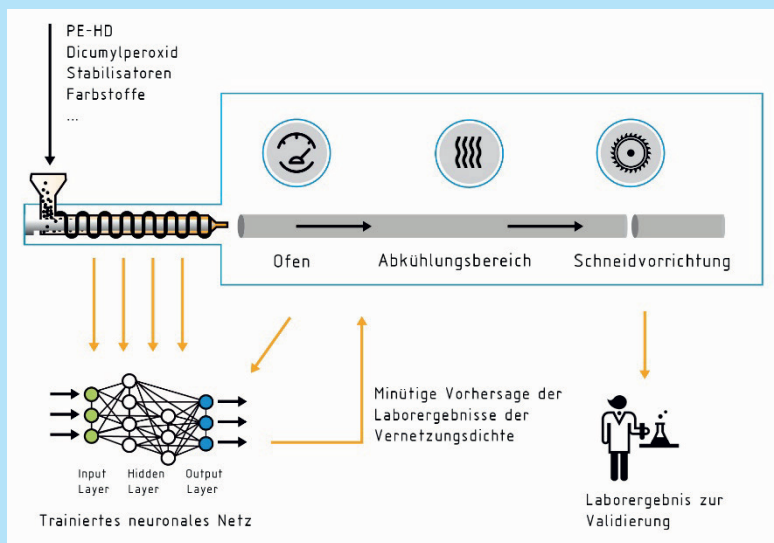


Abbildung 18: Produktionsprozess von Kunststoffrohren unter Miteinbeziehung eines trainierten neuronalen Netzes

Ergebnisse mit besonderem Bezug zur betrieblichen Ressourceneffizienz

Durch die Implementierung des trainierten neuronalen Netzes in den Produktionsprozess kann die Vernetzungsdichte nach aktuellem Stand minütlich mit einer Genauigkeit von 98,5 % vorhergesagt werden. Die Zeitverzögerung zwischen Produktion und Qualitätskontrolle wird somit minimiert und das Personal kann bei Abweichungen der Vernetzungsdichte sofort in den Produktionsprozess eingreifen, ohne dass weiterer Ausschuss produziert wird. Endergebnis, insbesondere relevant im Hinblick auf die Ressourceneffizienz, ist eine deutliche Reduzierung der Ausschussrate. Nach weniger als sechs Monaten hat sich das Projekt auch finanziell amortisiert.

5.5 AS 5: Planung der Prozesskette

Anwendungsszenario 5 beschreibt die Planung der Prozessketten am Beispiel der Simulation und Modellierung von Betriebszuständen in der Mikrofertigung (Abschnitt 5.5.1). Das Praxisbeispiel der Julius Zorn GmbH in Abschnitt 5.5.2 zeigt die Implementierung des Anwendungsszenarios in der Lagerhaltung und Produktionsplanung.

5.5.1 Simulation und Modellierung von Betriebszuständen in der Mikrofertigung

Die Mikrofertigung gewinnt eine immer größere Bedeutung, insbesondere in der Medizintechnik, aber auch in der Automobilindustrie. Dahinter steckt der weiter zunehmende Miniaturisierungsbedarf von Systemen bei gleichbleibender oder steigender Funktionalität. Die Prozessplanung in der Mikrofertigung ist jedoch mit einer hohen Komplexität verbunden und schon geringe Änderungen von Fertigungsparametern können erhebliche Mehrkosten und Qualitätsverluste nach sich ziehen. Die Miniaturisierung von Bauteilen, Komponenten und Fertigungsmaschinen führt oftmals zu veränderten physikalischen und technischen Eigenschaften und nicht selten zu Qualitätseinbußen. Das folgende Anwendungsszenario beschreibt den Einsatz eines generalisierten linearen Regressionsmodells zur Opti-

mierung des Fertigungsprozesses am Beispiel eines Mikro-Rundknetprozesses⁶³.

Tabelle 18 zeigt die für dieses Anwendungsszenario notwendige technologische Umsetzung im Detail. Das Ziel besteht darin, Prozessketten anhand verschiedener Eingabeparameter zu simulieren und gegenüber vordefinierten Zielgrößen zu optimieren. Der Mikro-Rundknetprozess lässt sich in vier Abschnitte unterteilen. Zunächst wird der zu verarbeitende Draht erhitzt und formbar gemacht. Mithilfe eines Lasers wird anschließend das Drahtende weiter erhitzt und gestaut, um eine Verdickung zu erzeugen. Im letzten Schritt erfolgt die Kaltumformung des verdickten Endes zu seiner endgültigen Form⁶⁴.

⁶³ Vgl. Freitag, M.; Kück, M.; Alla, A. A. und Lütjen, M. (2015).

⁶⁴ Vgl. Rippel, D.; Lütjen, M. und Scholz-Reiter, B. (2014).

Tabelle 18: Technologische Umsetzung von AS 4

Faktor	Beschreibung
Hardware	Keine zusätzliche Hardware benötigt.
Daten	Es werden Daten zu den vier Prozessparametern Vorschubgeschwindigkeit Schwingfrequenz, Schließdruck der Matriz e sowie Durchmesser des fertigen Drahtes gesammelt. Zusätzlich werden Daten zu logistischen Parametern wie Prozessdauer in Abhängigkeit von bearbeiteter Strecke, Materialverbrauch, Materialausschuss sowie Bearbeitungs- und Stillstandzeiten erhoben.
KI-Methode	Lineare Regression: Die lineare Regression ist eine Standardmethode zur Vorhersage von numerischen Zielvariablen. Dabei wird der Zusammenhang zwischen einer abhängigen Variablen von einer oder mehreren Zielvariablen untersucht. Es wird dabei ein linearer Zusammenhang zwischen der abhängigen und den unabhängigen Variablen angenommen. Alternativ können auch Support Vector Machines (SVM) und neuronale Netze verwendet werden. Diese eignen sich besonders für die Abbildung komplexer Zusammenhänge wie etwa nichtlineare Abhängigkeiten.
Wesentliche Arbeitsschritte	Wesentliche Arbeitsschritte in chronologischer Folge: <ul style="list-style-type: none"> • Durchführung von 55 experimentellen Durchläufen des Mikro-Rundknetprozesses zur Erhebung von Trainings- und Testdaten • Training eines linearen Regressionsmodells mit den Prozessparametern Vorschubgeschwindigkeit, Schwingfrequenz und Schließdruck der Matriz e als unabhängige Variablen. Als abhängige Variable dient der Durchmesser des fertigen Drahtes • Simulation unterschiedlicher Szenarien mit entsprechenden Prozessparametern • Erstellung von Materialflusssimulationen für die simulierten Szenarien • Evaluation der Szenarien anhand logistischer Faktoren wie Prozessdauer, Ausschussquote, Materialverbrauch oder Bearbeitungs- und Stillzeiten

Wichtig in der Mikroprozessplanung ist das Erfassen von Wirkzusammenhängen zwischen Prozessparametern und den daraus resultierenden Einflüssen auf Qualität, Kosten und zeitliche Ressourcen. Durch die Betrachtung einzelner Parameter kann der kausale Effekt auf das fertige Mikrobau teil quantifiziert werden, solange alle weiteren Systemeinstellungen unverändert bleiben. Für eine Untersuchung von Abhängigkeiten zweier Variablen eignen sich im besonderen Maße statistische Regressionsverfahren, die für die Optimierung der Mikrofertigung auch angewendet wurden. Mithilfe eines Regressionsmodells lassen sich Szenarien mit unterschiedlichen Prozessparametern beliebig simulieren. Dies ist insbesondere dann wertvoll, wenn es sich um einen komplexen Prozess handelt, der von einer Vielzahl von Parametern abhängt. Eine Simulation von Prozessauslegungen ist somit einem iterativen Testen aller Kombinationsmöglichkeiten aus ökonomischen Gründen vorzuziehen.

Tabelle 19: Aufwandseinschätzung für AS 4

Bewertungskriterium	Aufwand	Beschreibung
Implementierungsaufwand	gering	Der Implementierungsaufwand ist gering, da keine Integration in eine bestehende IT-Infrastruktur notwendig ist.
Software- und Hardwareaufwand	gering	Die Modellierung eines Regressionsmodells ist vergleichsweise simpel und lässt sich mit gängiger Open-Source-Software durchführen. Zusätzliche Hardware ist nicht notwendig, da die Daten direkt aus dem Fertigungsprozess erhoben werden können.
Erforderliches Fachwissen	mittel	Für die lineare Regressionsanalyse sind Programmierfähigkeiten nicht zwingend notwendig. Jedoch erfordert die Erstellung der Wirkzusammenhänge und Materialflusssimulationen sowie die Evaluierung der simulierten Szenarien fundierte Prozesskenntnisse.

Anhand der Simulation unterschiedlicher Prozessparameter lassen sich Materialflüsse für die entsprechenden Szenarien erstellen. Nach entsprechender Überprüfung der technischen Machbarkeit können die Szenarien hinsichtlich Ressourceneffizienz evaluiert und ausgewählt werden. Der hierfür notwendige Aufwand wird in Tabelle 19 genauer eingeschätzt und beschrieben. Es ergeben sich somit Einsparpotenziale gegenüber den eingesetzten Materialien, Werkzeugen und dem Energieaufwand (siehe Tabelle 20).

Tabelle 20: Qualitative Potenzialabschätzung von AS 4 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell

Ressource	Einfluss	Kennzahlen & Beschreibung
Material	mittel	Materialverbrauch in kg: Durch eine Optimierung der Produktionsparameter konnte die Ablehnungsquote von Mikrobauteilen reduziert werden. Damit sank unmittelbar der Materialverbrauch je gefertigtem Mikrobauteil. Realisiert durch die Materialflusssimulation und Evaluation der Szenarien anhand logistischer Faktoren wird somit von einem Einsparpotenzial im mittleren Maße ausgegangen.
Elektrische Energie	gering	Energieverbrauch in kWh: Durch die Verringerung von Ausfallzeiten lässt sich der Energieverbrauch verringern. Dadurch können Energieeinsparungen im geringen Maße erwartet werden.
Wasser	kein Einfluss	
THG-Emissionen	gering	Emission von kg CO₂e: Senkung des Ausstoßes an CO ₂ e, die sich aus der Materialeinsparung an Mikrobauteilen und der Verringerung der eingesetzten elektrischen Energie ergibt. Weitere sekundäre Effekte auf THG-Emissionen lassen sich aus Einsparungen in der Lieferkette ableiten. Insgesamt können somit Einsparungen im geringen Bereich erzielt werden.
Andere Effekte		<ul style="list-style-type: none"> • Einsparung von Bearbeitungs- und Stillstandzeiten • Reduktion von Rüstzeiten möglich

5.5.2 Praxisbeispiel AS 5: Julius Zorn GmbH

Optimierung der Lagerhaltung und Produktionsplanung mittels Forecast-Algorithmen

Vorstellung der Julius Zorn GmbH

Die Julius Zorn GmbH (Juzo) entwickelt und fertigt Produkte für die Kompressionstherapie und Orthopädie auf dem neuesten Stand der Forschung und Technik. Die Herstellung erfolgt mit modernster Technik und unter Einhaltung hoher Qualitätskriterien. Die individuellen Anforderungen und Wünsche der Kunden werden mithilfe neuester Technologien, wie beispielsweise computergesteuerten Strickmaschinen und digital gesteuerten Näh- und Farbmaschinen, umgesetzt.⁶⁵



⁶⁵ Vgl. Julius Zorn GmbH (2021).

Herausforderungen in der Lagerhaltung und Produktionsplanung

Die Herausforderung im Projekt liegt in der Erstellung verwertbarer Forecast-Zahlen, die eine praktische Anwendung für die betriebliche Ressourcenplanung finden und so maßgeblich zur Senkung der Kapitalbindung oder zu Kosteneinsparungen beitragen. Durch eine Potenzialanalyse hat sich ergeben, dass ein sehr großes Einsparpotenzial bei der Lagerhaltung und Produktionsplanung existiert, da diese Bereiche bisher ohne Zeitreihenanalyse geplant wurden. Über eine mit einem Forecast-Algorithmus gepaarte professionelle Zeitreihenanalyse, eine Planung des betrieblichen Ressourceneinsatzes (Mensch, Maschine, Material) im Bereich der Lagerhaltung und eine Produktionsplanung sollen die in der Vergangenheit existierenden Unterschiede zwischen Soll- und Ist-Zahlen minimiert und damit die Aussagekraft zukünftiger Planungen optimiert werden.

Lösung durch den Einsatz von KI

Durch eine Algorithmus-basierte Zeitreihenanalyse vergangener Verkaufszahlen kann ein monatlich rollierender Forecast mit hoher Genauigkeit erstellt werden. Dabei werden Open-Source-Lösungen genutzt, um die Herausforderung zu lösen. Zum Einsatz kommen die Programmiersprache R und die etablierte Bibliothek FPP2/FPP3 (Forecasting: Principles and Practice), welche professionelle Zeitreihenanalysen und Forecast-Modelle beinhaltet (siehe Tabelle 21).

Tabelle 21: Schritte und Hilfsmittel zur Optimierung der Lagerhaltung und Produktionsplanung

Herausforderung	Tools und Bibliotheken	Eingetretene Verbesserungen	Erreichte Einsparungen
<ul style="list-style-type: none"> • Erstellen eines monatlich rollierenden Forecasts zur Verbesserung der Vertriebs- und Produktionsplanung 	<ul style="list-style-type: none"> • Zeitreihenzerlegung und -Analyse • Holt-Winters (ETS) und ARIMA-Algorithmen • Programmiersprache R und Bibliothek FPP2/FPP3 	<ul style="list-style-type: none"> • Aufzeigen der Einflüsse von Saisonalität und Trends • Verbesserung der Forecast-Genauigkeit durch Verwendung bewährter Algorithmen zur Analyse von Zeitreihen und Erstellung von Forecasts 	<ul style="list-style-type: none"> • Reduzierung überflüssiger Lagerbestände für Fertigwaren • Reduzierung der Bestände von unfertigen Erzeugnissen und Rohmaterial • Einsparung laufender Lagerhaltungskosten
<ul style="list-style-type: none"> • Implementieren eines Werkzeugs zur Analyse von Preisangeboten 	<ul style="list-style-type: none"> • Regressionsanalyse • Base R und Bibliothek „moderndive“ 	<ul style="list-style-type: none"> • Werkzeug zur besseren Preisprognose • Aufdeckung von Anomalien in Angeboten für Rohmaterial und Zukaufteile • Preisverhandlungen können jetzt basierend auf Zahlen, Daten und Fakten geführt werden 	<ul style="list-style-type: none"> • 3 % - 5 % Reduktion bei direkten Materialkosten • Aufdeckung von Anomalien in Preisangeboten, die teilweise zu Nachverhandlungen mit signifikanten Einsparungen geführt haben
<ul style="list-style-type: none"> • Visualisierung von KPIs und Darstellung des Zielerreichungsstandes mit interaktiven Dashboards 	<ul style="list-style-type: none"> • Interaktive Datenvisualisierung („ggplot2“, „flexdashboard“ und „shiny“) 	<ul style="list-style-type: none"> • Unternehmensweite Kommunikation von KPIs und deren Zielerreichungsstand • Identifizierung von Abweichungen und schnelle Ergreifung von Gegenmaßnahmen 	<ul style="list-style-type: none"> • Reduktion der Stromkosten • Erhöhung der Maschinenauslastung • Reduzierung der Qualitätskosten und Verringerung von Ausschuss

Erfolgsfaktoren und Hemmnisse

Die größte Herausforderung besteht darin, sich das nötige Wissen im Bereich der Datenwissenschaften und Zeitreihenanalysen anzueignen. Diese Hürde kann durch eine Weiterbildung überwunden werden. Die Erfahrung hat gezeigt, dass mit ca. vier Stunden Training pro Woche bereits nach drei Monaten sehr gute verwertbare Ergebnisse erzielt werden können. Zusätzlich wird das Thema im Unternehmen auch anhand einer Bachelorarbeit in Zusammenarbeit mit der Hochschule Augsburg (Herr Professor Feucht, Dekan Fakultät für Wirtschaft) bearbeitet. Das Ziel besteht darin, die notwendige Kompetenz von Beginn an mit den eigenen Mitarbeitenden aufzubauen.

Sind Kenntnisse im Bereich Data Science im eigenen Team vorhanden, wird die Option für weitere mögliche Anwendungsgebiete innerhalb des Unternehmens geschaffen. Durch eine konsequente Fortbildung der Mitarbeitenden sind unter anderem grundsätzliche Fähigkeiten zu folgenden Technologien vorhanden:

- Big-Data-Anwendungen,
- professionellen statistischen Analysen,
- interaktiven Visualisierungen und Datenanalysen,
- Prozessautomatisierung durch Anwendung von anwendungsspezifischem Code,
- Entwicklung und Einsatz von Algorithmen,
- maschinellem Lernen sowie
- KI-Anwendungen (neuronalen Netzwerken, Deep Learning).

Ergebnisse mit besonderem Bezug zur betrieblichen Ressourceneffizienz

Durch die Verwendung der Daten aus dem Holt-Winters-Forecast ist die Material- und Produktionsplanung sehr präzise möglich. Bei der Planung der notwendigen betrieblichen Ressourcen kann schnell auf Trends und saisonale Veränderungen reagiert werden, da diese in den Forecast-Modellen sichtbar gemacht und so in der Planung berücksichtigt werden können. Die Verwendung der Programmiersprache R und des Pakets

FPP3 sowie der Einsatz eines Algorithmus ermöglichen die automatisierte Erstellung des Forecasts, der durch mehrere graphische Analysemöglichkeiten der Zeitreihen und Forecast-Modelle ergänzt wird. Diese helfen zusätzlich bei der Ressourcenplanung.

Folgende Ergebnisse wurden erzielt:

- Die Produktion kann sehr präzise zwölf Monate im Voraus geplant werden.
- Die Lagerbestände sinken um 12 %.
- Die Fertigwarenbestände können sehr präzise auf die richtige Reichweite gesteuert werden. Dadurch wird das gebundene Kapital um 10 % reduziert.

Fehlbestände (Stock-outs) sind auf historisch niedrigem Stand.

5.6 AS 6: Produktoptimierung

In diesem Anwendungsszenario wird zunächst in Abschnitt 5.6.1 eine Methodik zur datengetriebenen Produktplanung und Retrofit-Planung vorgestellt und deren positive Effekte auf die Ressourceneffizienz werden diskutiert. Das Praxisbeispiel der IANUS Simulation GmbH in Abschnitt 5.6.2 zeigt die Implementierung des Anwendungsszenarios zur Optimierung von Extrusionswerkzeugen.

5.6.1 Methodik zur datengetriebenen Produktgenerierung und Retrofit-Planung

Industrie 4.0 und Digitalisierung haben das verarbeitende Gewerbe in vielerlei Hinsicht verändert und bieten Unternehmen die Möglichkeit, Produkte in zukünftigen Generationen und Nachrüstungen durch das Lernen aus Produktnutzungs- und Verhaltensdaten systematisch zu verbessern. Da die Nutzung dieser Daten keinesfalls trivial ist, wird im Folgenden das Anwendungsszenario zur datengetriebenen Produktgenerierung und Retrofit-Planung vorgestellt⁶⁶. Die Methodik umfasst alle Schritte von der datenbasierten Identifikation von Optimierungspotenzialen bis hin zu der Umsetzung von Verbesserungen in zukünftigen Produktgenerationen und

⁶⁶ Vgl. Meyer, M.; Frank, M.; Massmann, M.; Wendt, N. und Dumitrescu, R. (2020).

Retrofits. Für die Potenzialanalyse dieser Methodik sind die technologische Umsetzung (Tabelle 22), die Aufwandseinschätzung (Tabelle 23) und die Potenzialabschätzung hinsichtlich Ressourceneffizienz (Tabelle 24) jeweils tabellarisch zusammengefasst worden.

Die Vorteile eines datengesteuerten Ansatzes für die strategische Produktplanung sind zahlreich und lassen sich in drei Kategorien einteilen: zum einen in tiefe Kundeneinblicke durch die Möglichkeit, latente Kundenbedürfnisse zu identifizieren und diese in zukünftigen Produktgenerationen oder Nachrüstungen zu adressieren, zum anderen in fundierte Produkteinsichten durch ein tiefgehendes Verständnis für das Produkt sowie seine Stärken und Schwächen. Die dritte Kategorie bildet das Ableiten von Schlussfolgerungen durch die sorgfältige Analyse der gesammelten Daten. Hierdurch werden bessere Entscheidungen im Produktplanungs- und Entwicklungsprozess ermöglicht.

Tabelle 22: Technologische Umsetzung von AS 6

Faktor	Beschreibung
Hardware	Nicht näher erläutert.
Daten	<p>Komplexe technische Systeme haben hunderte möglicher Datenpunkte. Da es einen enormen Aufwand erfordert, alle eventuell auftretenden Beziehungen zwischen den Daten zu analysieren, wird so früh wie möglich ein Fokus auf bestimmte Aspekte und Datenpunkte gesetzt. Hilfreich ist hierbei das Herleiten von Hypothesen über Produktnutzung und Kundenverhalten, um Ansatzpunkte für die Datenanalyse zu finden. Dies kann anhand eines fünfstufigen Prozesses geschehen:</p> <ul style="list-style-type: none"> • Aufstellen eines partiellen Modells → generelles Produktverständnis • Erstellen von Wertversprechen → Katalog der Handlungsfelder • Clustering und Priorisierung → zu untersuchende Handlungsfelder • Ermittlung der Einflussfaktoren → Einflussfaktoren auf die Handlungsfelder • Bestimmung der Hypothesen
KI-Methode	<p>Wenn die notwendigen Daten vorhanden sind, können die Hypothesen getestet werden. Dazu muss eine geeignete Methode aus den folgenden sechs Kategorien gewählt werden:</p> <ul style="list-style-type: none"> • Visualisierung: z. B. Plots und Projektionen • Korrelation: z. B. Kovarianz- und Chi-Quadrat-Test • Regression: z. B. lineare Regression, nichtlineare Regression und Multilayer Perceptron • Vorhersage: z. B. autoregressive Modelle und rekurrente neuronale Netze • Klassifikation: z. B. Support Vector Machine, Nearest Neighbour Klassifikation und Entscheidungsbäume • Clustering: z. B. sequentielles und partielles Clustering
Wesentliche Arbeitsschritte	<p>Die Vorgehensweise der Methodik zur datengesteuerten Produktgenerierung und Retrofit-Planung ist durch ein dreiphasiges Prozessmodell realisierbar:</p> <ol style="list-style-type: none"> 1. Hypothesenfindung und Priorisierung <ol style="list-style-type: none"> a. Bestimmung der Hypothesen b. Priorisierung der Hypothesen → priorisierte Hypothesen 2. Datenanalyse: <ol style="list-style-type: none"> a. Identifikation der benötigten Daten für die Validierung b. Datengesteuerte Validierung der Hypothesen → validierte Hypothesen 3. Ableitung von Produktverbesserungen: <ol style="list-style-type: none"> a. Ableitung und Bewertung von Produktverbesserungen b. Ermittlung der Auswirkungen auf die Produkterzeugung und Retrofit-Planung. → Handlungsempfehlungen

Um Produktverbesserungen ableiten zu können, wird das Prinzip der Konkretisierung bzw. Abstraktion der widerspruchsorientierten Kreativitätsmethode angewendet. Dabei wird zunächst die zu betrachtende Hypothese abstrahiert. Anschließend wird untersucht, welcher Aspekt des Produkts verbessert werden sollte und ob diese Verbesserung eine unerwünschte Veränderung im Nutzenversprechen darstellen würde.

Der Bereich, in dem sich die ausgewählten Aspekte und Datenpunkte überschneiden, definiert abstrakte Lösungsprinzipien. Diese werden auf den Einflussfaktor der Hypothese angewendet und führen zu einer konkreten Lösung. Die identifizierten Produktverbesserungen werden anschließend hinsichtlich ihrer Auswirkungen auf die Produktentstehung und Nachrüstplanung untersucht. Dieser Schritt dient der Prüfung, ob die Verbesserung als Retrofit realisiert oder erst in einer neuen Produktgeneration umgesetzt werden sollte. Die Entscheidung hängt von zwei Kriterien ab: der Komplexität der Änderung bei der Umsetzung der gewünschten Produktverbesserung und der Wahrscheinlichkeit von Kannibalisierungseffekten. Die Komplexität bestimmt, ob sich die Änderung auf einzelne Komponenten beschränkt oder große Teile der Produktstruktur umfasst. Bei letzterem steigt die Wahrscheinlichkeit, wenn eine fehlende Produktdifferenzierung besteht. Folglich muss sich eine neue Produktgeneration durch einen Zusatznutzen von einem Retrofit abheben, um Kannibalisierungseffekte zu vermeiden.

Tabelle 23: Aufwandseinschätzung für AS 6

Bewertungskriterium	Aufwand	Beschreibung
Implementierungsaufwand	hoch	Eine Infrastruktur ist notwendig, um die Daten aus den verschiedenen Geschäftsbereichen zu sammeln und mit eventuellen externen Daten zu integrieren und auszuwerten.
Software- und Hardwareaufwand	gering	Für die hier beschriebene Methodik können Open Source-Frameworks verwendet werden.
Erforderliches Fachwissen	hoch	Zum einen ist in der Produktion ein technisches Verständnis zur Erhebung und insbesondere zur Interpretation der gesammelten Daten notwendig. Zum anderen handelt es sich bei den verwendeten KI-Algorithmen unter anderem um komplexe neuronale Netze, deren Auswahl, Optimierung und Ergebnisinterpretation in der Datenanalyse ein tieferes Verständnis und teilweise Programmierkenntnisse erfordern.

Die Handlungsempfehlungen ergeben sich aus der Bewertung der Produktverbesserungen hinsichtlich der beiden genannten Kriterien. Wenn die Komplexität der Änderung und die Wahrscheinlichkeit von Kannibalisierungseffekten gering ist, wird ein Retrofit empfohlen. Wenn eines der Kriterien oder beide als hoch eingestuft werden, sollte die Produktverbesserung ausschließlich in einer neuen Produktgeneration umgesetzt werden.

Der hier beschriebene Ansatz wurde in fünf verschiedenen Fallstudien angewendet. Nach der Erfahrung und dem Feedback der Teilnehmenden bietet diese Methodik eine sehr effiziente Möglichkeit, Produktverbesserungen auf Basis der Datenanalyseergebnisse abzuleiten. Ein wesentlicher Grund dafür ist die systematische Identifikation von Hypothesen bezüglich des Produkts. Diese führen direkt zu den zu analysierenden Daten als auch zu Ansatzpunkten für die Suche nach Produktverbesserungen. Darüber hinaus erweist sich insbesondere der modellbasierte Ansatz für den Aufbau eines tiefgreifenden Produktverständnisses und die Suche nach Faktoren für Erfolgskriterien als geeignet. Hochwertige Modelle zeichneten sich in sämtlichen Fallstudien durch einen erheblichen Einfluss auf die Qualität der Ergebnisse aus und wurden in vielen Phasen des Prozesses herangezogen.


Tabelle 24: Qualitative Potenzialabschätzung von AS 6 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell

Ressource	Einfluss	Kennzahlen & Beschreibung
Material	mittel	Materialverbrauch in kg: Mit der Produkt- oder auch Werkzeugoptimierung geht ein Einsparpotenzial in Bezug auf eingesetztes Material einher, wodurch beispielsweise Nacharbeit wegfällt. Dies führt unmittelbar zu einem geringeren Materialverbrauch in der Produktion. Je nach Ausschussquote und deren prozentualen Veränderung sind Einsparungen im mittleren Maße zu erwarten.
Elektrische Energie	hoch	Energieverbrauch in kWh: Auch hier kann ein positiver Nebeneffekt durch die Produkt-/Werkzeugoptimierung verzeichnet werden. Im nachfolgenden Praxisbeispiel werden Iterationen bei jährlichen Anfahrprozessen von Maschinen um mehr als die Hälfte reduziert. Dadurch können enorme Einsparungen der Energieverbräuche realisiert werden, die auf ein Einsparpotenzial im hohen Maße schließen lassen.
Wasser	kein Einfluss	
THG-Emissionen	gering	Emission von kg CO₂e: Senkung des Ausstoßes an CO ₂ e die sich aus Materialeinsparung und Verringerung der eingesetzten elektrischen Energie gibt. Weitere sekundäre Effekte auf THG-Emissionen lassen sich aus Einsparungen in der Lieferkette ableiten. Insgesamt können somit Einsparungen im geringen Bereich erzielt werden.
Andere Effekte		In einer der von den Autoren erwähnten Fallstudien wird die Anwendung der vorgestellten Methodik am Beispiel eines modularen Gehäusesystems demonstriert. Dabei wird durch eine Treiberanalyse festgestellt, dass die Deckelverschraubung Hauptgrund einer zeitintensiven Handhabung im Servicefall ist. Im finalen Teil der Datenanalyse wird die Deckelverschraubung mit anderen Handhabungsoptionen verglichen und eine bessere Lösung identifiziert. Hierbei ist der zu verbessernde Parameter der Zeitverlust bei der Wartung, der nur einen von vielen möglichen weiteren Effekten einer datengetriebenen Produktentwicklung darstellt.

5.6.2 Praxisbeispiel AS 6: IANUS Simulation GmbH und M+S Silicon GmbH & Co. KG

KI-gestützte Optimierung von Extrusionswerkzeugen

Vorstellung der IANUS Simulation GmbH und der M+S Silicon GmbH & Co. KG

Die IANUS Simulation GmbH wurde 2006 als Spin-off-Unternehmen der  TU Dortmund gegründet und ist heute ein Software- und Dienstleistungspartner für 3D-CF-Simulation von Strömungsprozessen. Diese numerischen Strömungssimulationen (CFD-Simulationen) werden beispielsweise in der Kunststoff-, Pharmazie- und Lebensmitteltechnik eingesetzt und ermöglichen einen detaillierten Einblick in die Prozesse und Vorgänge unterschiedlicher Maschinen, in denen Strömungen vorliegen. Mithilfe sogenannter digitaler Zwillinge, welche IANUS mit seinen mehr als 30 Mitarbeitenden der Kundschaft aus unterschiedlichsten Branchen anbietet, können Prozesse ressourcen- und energieeffizient ausgelegt und optimiert werden.⁶⁷

Der in diesem Praxisbeispiel vorgestellte Kunde ist die M+S Silicon GmbH & Co. KG⁶⁸. Diese bildet den Ursprung der M+S Gruppe in Dortmund und wurde 2001 gegründet. M+S hat sich auf die Herstellung von Extrudaten, Eckenvulkanisationen und HTV-Formteilen, die in jedem gewünschten Farbton und auf der Grundlage von individuellen Mustern, Datensätzen oder Zeichnungen gefertigt werden können, spezialisiert. Ca. 250 Mitarbeitende verarbeiten Silikonkautschuk in vielfältigen Varianten. Der Werkstoff passt sich den unterschiedlichsten Ansprüchen hinsichtlich Form und Design optimal an.

Herausforderungen des Kunden

Die Firma M+S Silicon verarbeitet diverse Profile, Schläuche, Schäume und Platten aus Silikonkautschuk für über zehn verschiedene Branchen unter höchsten qualitativen Ansprüchen. Diese werden neben dem

⁶⁷ Vgl. IANUS Simulation GmbH (2021).

⁶⁸ Vgl. M+S Silicon GmbH & Co. KG (2021).

Spritzgussverfahren vor allem über das Extrusionsverfahren hergestellt und erfordern hohe fachliche Kenntnisse, um den Verarbeitungsprozess stabil zu führen.

Da der Markt die Herstellung von qualitativ hochwertigeren und technisch anspruchsvolleren Produkten fordert, ist eine iterative Anpassung der formgebenden Extrusionswerkzeuge mithilfe von „Trial & Error“ üblich und oftmals sogar zwingend notwendig. Nur so können die finalen Endprodukte unter wirtschaftlichen Kriterien produziert werden.

Ein Extrusionswerkzeug hat die Aufgabe, die vom Extruder homogen bezogene Kunststoffschmelze in eine vom Kunden vorgegebene Profilform zu bringen. Dafür ist die entsprechende Werkzeugauslegung – also die Planung und Entwicklung der späteren Werkzeugform – ein signifikanter Faktor. Das Auslegen von Extrusionswerkzeugen ist sehr komplex sowie zeitaufwändig und erfolgt auf Grundlage von Erfahrungswerten. Durch die Komplexität der jeweiligen Werkzeuge besteht allerdings ein hohes Fehlerpotenzial. Fehler in der Werkzeugauslegung werden in der Einfahr- bzw. Bemusterungsphase durch „Trial&Error“-Versuche korrigiert. Dieser Vorgang ist besonders zeit- und kostenaufwändig.

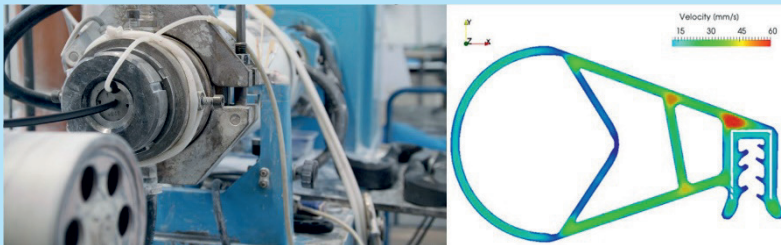


Abbildung 19: Austritt eines Profils aus dem Extrusionswerkzeug & Visualisierung der inhomogenen Geschwindigkeitsverteilung am Austritt

Lösung durch den Einsatz von KI

Für die theoretische Betrachtung der Strömungsvorgänge in der Auslegung von Werkzeugen bilden mathematische Modellierungen die Grundlage. Mithilfe modernster numerischer Methoden können die Strömungen in Extrusionswerkzeugen simulativ dargestellt werden. Damit ist es möglich, bestimmte Parameter in der Prozessverarbeitung zu generieren, welche Erkenntnisse über den Prozess bieten. Inhomogene Strömungs-

geschwindigkeiten (siehe Abbildung 19) am Extruderaustritt können beispielsweise in unterschiedlichen Wanddicken des Produkts oder im „Herausbiegen“ des zu produzierenden Werkstückes aus dem Extruder resultieren. Zu hohe Verweilzeiten der Strömung im Werkzeug weisen oft auf Totzonen hin und können in Stippen auf dem Produkt resultieren. Zudem bedeutet ein zu hoher Druckverbrauch eine schlechte Energieeffizienz, da der Extruder mehr Leistung erbringen muss.

Aufbauend auf diesen bereits bekannten numerischen Ansätzen für die Simulation von Strömungsprozessen hat IANUS ein System entwickelt, mit dem solche Strömungssimulationen auch speziell durch den Anwendenden schnell und einfach durchgeführt werden können, Strömungsraum©. Die Simulation läuft dabei auf Hochleistungsrechenclustern ab, um eine größtmögliche Rechenleistung und schnelle Ergebnislieferung zu garantieren. Des Weiteren kann das System individuell an besondere Kundenwünsche, Anforderungen sowie die jeweiligen Prozesse angepasst werden - so auch an den individuellen Workflow der Firma M+S. Mit dieser Software-App ist die Firma M+S jederzeit über ein internetfähiges Endgerät in der Lage, eine Strömungssimulation innerhalb von Minuten zu definieren und zu beauftragen.

Das System ist außerdem fähig, mithilfe schwacher KI eigenständige Lösungsvorschläge zu erarbeiten bzw. Werkzeugkonturen vorzuschlagen. Diese Vorschläge werden anhand von Algorithmen ermittelt und durch vorherige Datenerhebungen zusammen mit dem Kunden validiert. Ein Beispiel hierzu sind die evolutionären Algorithmen, die in zwei Stufen arbeiten: In einem ersten Schritt werden Simulationen für eine bestimmte Generation (Auswahl) von Parametern durchgeführt und deren Einfluss auf die zu optimierende Zielgröße bestimmt. Hier ist die Automatisierung essenziell, da sehr viele Simulationen für die unterschiedlichen Parameterkonfigurationen durchgeführt werden müssen. Aus den Simulationsergebnissen werden nun in einem zweiten Schritt diejenigen Parameterkonfigurationen durch einen Algorithmus ausgewählt, die zu einer Verbesserung der Zielgröße führen. Bei jedem Auswahlschritt wird der Auswahlalgorithmus leicht angepasst („mutiert“), sodass eine Evolution zu immer besseren Konfigurationen hin erfolgt. Das System durchläuft so lange verschiedene Konfigurationen, bis die gewünschten Ziel-

kriterien erreicht sind. Evolutionäre Algorithmen sind zielführend, aber gleichzeitig auch immer sehr aufwendig und simulationsintensiv.

Aufbauend auf den Simulationsergebnissen erhält die konstruierende Person Empfehlungen, wie das Werkzeug optimiert werden kann. Die Person, die das Werkzeug konstruiert, ist damit in der Lage, einfache Änderungen in der Geometrie des digitalen Werkzeugzwillings schnell selbstständig vorzunehmen. Das Arbeiten mit StrömungsRaum© ermöglicht, frühere Technologiehürden abzubauen, da weder eigene Hardware noch spezielles Wissen über die Software nötig sind. Diese moderne Art der numerischen Werkzeugauslegung unterstützt die klassische Auslegung, welche bislang ausschließlich durch die Person, die das Werkzeug konstruierte, erfolgte. Die Berechnungen sind stets abhängig vom jeweiligen Materialverhalten, weshalb die Firma M+S eigens ein Hochdruckkapillarrheometer erworben hat, um Materialcharakterisierungen eigenständig vorzunehmen. Damit können das Material und die eigene Rezeptur direkt vor Ort vermessen und bestimmt werden.

Erfolgsfaktoren und Hemmnisse

Die speziellen Materialeigenschaften sowie das kundenindividuelle Produktionsverfahren stellen eine große Herausforderung dar, die stets zu Projektbeginn gelöst werden muss. Mithilfe des Kunden und entsprechender Prozessdaten, die erfasst, strukturiert und aufbereitet werden, können Grundlagen des Codes adaptiert und zielorientierte Ergebnisse generiert werden. Hierdurch wird die KI befähigt, iterative Lösungsansätze zu finden. Eine weitere Herausforderung besteht darin, die Bereitschaft der Mitarbeitenden zu gewinnen und diese zu motivieren, sich neben dem Tagesgeschäft mit einer für sie neuen und unbekanntem Technologie zu beschäftigen sowie diese produktiv in den alltäglichen Workflow einzubeziehen.

Ergebnisse mit besonderem Bezug zur betriebliche Ressourceneffizienz

Nachfolgend wird skizziert, welche Einsparungen im Anfahr- bzw. Rüstprozess durch Digitalisierung und KI erzielt werden können. Ausgehend von ca. 100 neuen Werkzeugen pro Jahr bei der Firma M+S sind exemplarisch ca. acht Nacharbeitungsschleifen je neuem Werkzeug üblich.

Damit ergeben sich insgesamt ca. 800 jährliche Anfahrprozesse, die einen entsprechenden Ausschuss verursachen. Zusammen mit einem Materialpreis von derzeit ca. 4,30 €/kg und einer Extruderfüllung von ca. 30 kg Material pro Anfahrversuch ergeben sich Verluste von ca. 103.000 € sowie 16.200 kWh Energiebedarf pro Jahr (ausgehend von einem normalen Energieverbrauch bei einem durchschnittlich eingesetzten Extruder). Im Schnitt wird die Anzahl der Anfahrprozesse mithilfe von StrömungsRaum© von acht auf drei Iterationen verringert, was wiederum eine Gesamtersparnis von ca. 66.200 €/Jahr ergibt.

5.7 AS 7: Autonome Transportsysteme

Anwendungsszenario 7 beschreibt den Einsatz autonomer Transportsysteme am Beispiel der Automatisierung in der Produktionslinie durch fahrerlose Transportsysteme (FTS) in einem Lebensmittelunternehmen (Abschnitt 5.7.1). Das Praxisbeispiel der Blechwarenfabrik Limburg GmbH in Abschnitt 5.7.2 zeigt, wie durch die Implementierung dieser Systeme Ressourceneinsparungen und Effizienzgewinne in der Intralogistik erreicht werden können. Bei beiden Anwendungen wurde eine integrale Gesamtlösung von FTS mit KI-Unterstützung gewählt. Der Zwischenschritt von FTS ohne KI-Unterstützung wurde im Übergang von einer manuellen zu einer KI-gestützten Lösung übersprungen. Das reine KI-Potenzial kann daher nur schwer von der Gesamtlösung getrennt werden.

5.7.1 Automatisierung der Produktionslinien durch fahrerlose Transportsysteme

Unternehmen müssen ihre Prozesse stetig verbessern, um die Produktion zu flexibilisieren, Wartezeiten zu reduzieren und die Produktivität durch kleinere Zeitintervalle zu erhöhen. Um diese Ziele zu erreichen, werden effiziente und automatisierte Transport- und Materialhandhabungssysteme benötigt. Dabei haben sich mit dem rasanten Fortschritt der Robotertechnologien sogenannte fahrerlose Transportsysteme (FTS) in verschiedenen Bereichen durchgesetzt, z. B. bei der Kommissionierung und Auslieferung

von Lagerware oder dem innerbetrieblichen Materialtransport. In der folgenden Praxisanwendung wird eine wirtschaftliche Bewertung des Einsatzes von FTS in einem Lebensmittelunternehmen dargestellt⁶⁹.

FTS sind mobile Geräte, die typischerweise in industriellen Anwendungen als automatisierte Hilfsmittel für den Transport von Materialien von Abholstellen zu Abgabestellen (d. h. Materialtransportaufgaben) eingesetzt werden. Sie finden insbesondere in Einrichtungen wie Distributionszentren, Fertigungsanlagen, Terminals und Lagern Verwendung. FTS sind mit einem zentralen Navigationssystem verbunden, das die Anweisungen an die Fahrzeuge sendet, ihre Positionsinformationen über verschiedene Onboard-Sensoren erhält und sie bei der Erledigung der entsprechenden Transportaufgaben entlang zuvor festgelegter Pfade führt. Dieses Projekt wurde in einem Lebensmittelunternehmen mit Sitz in Norditalien durchgeführt, welches tiefgekühlte Ferticlebensmittel herstellt, den Großhandel beliefert und 55 Länder weltweit erreicht. In dem genannten Unternehmen transportiert das FTS Zutaten für die Zubereitung der Lebensmittel aus den Küchen zu den Produktionslinien. Tabelle 25 verdeutlicht die dafür notwendige technologische Umsetzung im Unternehmen.

⁶⁹ Vgl. Tebaldi, L.; Di Maria, G.; Volpi, A.; Montanari, R. und Bottani, E. (2021).

Tabelle 25: Technologische Umsetzung von AS 7

Faktor	Beschreibung
Hardware	Abhängig vom Automatisierungsgrad muss eine bestimmte Anzahl von FTS vom Unternehmen gekauft werden. In diesem Fall werden bei Vollautomatisierung des Prozesses acht FTS akquiriert.
Daten	<p>Die wichtigste Datenquelle für die Erstellung der Analyse ist die Anzahl benötigter Fahrten/Transporte oder ihr jeweiliger Materialbedarf. Ausgehend von diesen Daten wurden die folgenden weiteren Elemente berechnet:</p> <ul style="list-style-type: none"> • Menge der beteiligten Rohstoffe für das gesamte Jahr [kg/Jahr]. • Anzahl der Tablettts [Tablettts/Jahr] <p>Anzahl der im aktuellen Szenario benötigten Mitarbeitenden. Diese wurde auf der Grundlage der täglichen geplanten Produktion während einer Arbeitsschicht abgeleitet.</p>
KI-Methode	KI kommt bei der Priorisierung von Aufträgen und der Bestimmung optimaler Fahrwege zum Einsatz, um die Produktionslinien jederzeit mit Material versorgen zu können und Pufferplätze nicht zu überlasten.
Wesentliche Arbeitsschritte	Zu Beginn sind ein Überblick und eine Analyse der Ist-Situation notwendig, um daraus eine detaillierte Transportanalyse durchführen zu können. Anschließend werden Randbedingungen und Grundannahmen definiert. Dazu gehören z. B. Platzbeschränkungen, Fahrzeugcharakteristika oder die erforderlichen Aufgaben der bedienenden Person. Anschließend können alle oben genannten relevanten Daten gesammelt werden. Darauf basierend wird unter Berücksichtigung einer Szenarioanalyse eine Investitionsbewertung vorgenommen. Letzter Schritt ist die Implementierung des FTS.

Bisher werden die Zutaten per Hand auf einzelnen Standardtablettts auf einem Wagen zu den verschiedenen Linien gebracht. Einer der wesentlichen Nachteile besteht darin, dass jeweils nur ein Tablett transportiert werden kann. Dieses ineffiziente System erfordert mindestens eine anwesende Person. Es werden hohe Arbeitskosten verursacht, da für bestimmte Produktionen zwei oder drei Personen gleichzeitig erforderlich sind. Die Automatisierung dieses Prozesses zielt darauf ab, diese Problematik zu lösen. Die untersuchte Betriebsstätte besteht aus drei verschiedenen Produktionslinien, die alle in der durchgeführten Analyse berücksichtigt werden. Für die Durchführung der vorliegenden Untersuchung soll der Ausgangszustand der zu bewertenden Anlage aufgenommen und eine detaillierte Analyse des Transports der Zutaten von den Küchen zu den Produktionslinien durchgeführt werden. Es werden direkte Beobachtungen im Produktionsbereich vorgenommen, um die Wege der Zutaten von der Zubereitung in den Küchen bis zur Ankunft an den Produktionslinien zu ermitteln. Während der Beobachtungen wurde die Zeit gemessen und aufgezeichnet, die jeder Mitarbeitende benötigte, um die Rohstoffe zu transportieren, zu wiegen, abzuladen, die leeren Tablettts aufzunehmen und wieder zurück in die Küchen zu bringen. Ausgehend von den gegebenen Räum-

lichkeiten und Wegen für den Transport der Zutaten wurde zunächst die Länge aller möglichen Wege berechnet. Die Division der Weglänge durch die Durchschnittsgeschwindigkeit jeder angestellten Person erlaubt eine Abschätzung der Zeit, die für das Zurücklegen aller möglichen Wege zwischen Küchen und Produktionslinien benötigt wird. Die weitere Einschätzung des Aufwands bezüglich Implementierung, Soft- und Hardware sowie des erforderlichen Fachwissens wird in Tabelle 26 aufgezeigt.

Tabelle 26: Aufwandseinschätzung für AS 7

Bewertungskriterium	Aufwand	Beschreibung
Implementierungsaufwand	hoch	Der Aufwand für die Einführung von FTS wird als hoch eingeschätzt. Neben ökonomischen Voranalysen zur Beurteilung der Wirtschaftlichkeit und Effizienz müssen neue Systeme in die Produktionsprozesse integriert und abgestimmt werden. Zudem müssen Mitarbeitende mit dem neuen Produktionsprozess vertraut gemacht werden.
Software- und Hardwareaufwand	keine Angabe	Es werden keine Angaben über die verwendete Software gemacht. Diese wird jedoch mit sehr hoher Wahrscheinlichkeit vom Hersteller der FTS bereitgestellt. Neben der Beschaffung der FTS müssen in dieser Praxisanwendung noch Magnetstreifen und Laser verbaut werden, da sich die FTS daran orientieren und die Produktionslinien bedienen.
Erforderliches Fachwissen	mittel	Die Einführung des neuen Systems stellt die größte Hürde dar. Da hier jedoch in der Regel eine geeignete Software zur Bedienung der FTS vom Hersteller bereitgestellt wird, müssen lediglich die Personen hinsichtlich der Bedienung der FTS geschult werden, die das neue System unter Berücksichtigung der optimalen Routen und erforderlichen Arbeitsschritte in den neuen Produktionsprozess einbetten.

Die Ergebnisse dieser Auswertung zeigen, dass der Mensch für das Zurücklegen der Gesamtstrecke, d. h. hin und zurück, weniger Zeit als das FTS benötigte. Während jedoch das Personal nur ein Tablett transportieren kann, erlaubt der Einsatz eines FTS den Transport von bis zu sechs Tabletts. Insgesamt kann ein Mitarbeitender etwa 165 kg Zutaten pro Stunde transportieren, ein Shuttle erreicht 600 kg. Dies verdeutlicht die signifikanten Einsparungsmöglichkeiten, die der Einsatz eines FTS in Bezug auf Ressourcen, Zeit und Personal (siehe Tabelle 27) mit sich bringt.

Tabelle 27: Qualitative Potenzialabschätzung von AS 7 zur Steigerung der Ressourceneffizienz in Anlehnung an das Kennzahlenmodell

Bewertungskriterium	Aufwand	Beschreibung
Material	mittel	Materialverbrauch in kg: Durch die Einführung eines FTS können Zutaten eingespart werden, da menschenverursachte Beschädigungen beim Transport sowie eine Unterbrechung der Kühlkette vermieden werden. Die Verringerungen der Ausschussmenge lässt Einsparungen im mittleren Maße erwarten.
Elektrische Energie	gering	Energieverbrauch in kWh: Kühlketten und Kühllager können energieeffizienter gestaltet werden, was damit auch zur Verringerung der Energieverbräuche führt. Da hierbei lediglich eine indirekte Energieeinsparung erzielt wird, ist das Potenzial zur zusätzlichen Energieeinsparung als gering zu betrachten.
Wasser	kein Einfluss	
THG-Emissionen	mittel	Emission von kg CO₂e: Senkung des Ausstoßes an CO ₂ e, die sich aus Materialeinsparung in Form von Zutaten, der Verringerung der Anzahl der Transporte bei einer Optimierung der Fahrwege und der Verringerung der eingesetzten elektrischen Energie ergibt. Weitere sekundäre Effekte auf THG-Emissionen lassen sich aus Einsparungen in der Lieferkette ableiten. Insgesamt können somit Einsparungen im mittleren Bereich erzielt werden.
Andere Effekte	hoch	Deutliche Zeit und Personaleinsparungen. Bei Vollautomatisierung der Produktionslinien werden 600 kg/h Rohmasse (anstelle von 165 kg/h durch einen Mitarbeitenden) transportiert.

Für die vollständige Automatisierung der Produktionslinien werden insgesamt acht FTS benötigt. Besonders interessant ist die Amortisationszeit, die etwa ein Jahr und acht Monate beträgt. Die anfängliche Investition wird durch jährliche Einsparungen in Höhe von ca. 279.000 € gerechtfertigt. Die Investitionsbewertung zeigt, dass eine Vollautomatisierung mit einem Kapitalwert von ca. 290.000 € die lukrativste Lösung darstellt.

5.7.2 Praxisbeispiel AS 7: Blechwarenfabrik Limburg GmbH

Prozessoptimierte Transporte durch ein intelligentes fahrerloses Transportsystem

Vorstellung der Blechwarenfabrik Limburg GmbH

Die Blechwarenfabrik Limburg GmbH ist Hersteller von Stahlverpackungen für sogenannte chemisch-



technische Füllgüter wie Farben, Lacke und Lasuren. Das Unternehmen hat weitere Standorte in Dänemark, Polen sowie Russland und ist mit fast 150 Jahren einer der ältesten Stahlverpackungshersteller in Deutschland.⁷⁰

Herausforderungen der wachsenden Produktion und des Materialtransports

Das alte Firmengebäude der Blechwarenfabrik lag mitten in der Limburger Innenstadt und war über 120 Jahre alt. Die Produktion war über die Jahre gewachsen und der Produktionsprozess entsprechend ineffizient gestaltet. Die Fertigung lief über vier Stockwerke. Material wurde mithilfe von Gabelstaplern transportiert und Höhenunterschiede wurden über Aufzüge bewältigt. Demnach war ein hoher und fehlerbehafteter logistischer Aufwand vonnöten, um den Materialtransport bewerkstelligen zu können.

Lösung durch den Einsatz von KI

Zur Lösung dieser Herausforderungen entschied sich das Unternehmen für den Bau eines neuen Standorts. Dabei wurde der Materialfluss als eines der zentralen Themen optimiert. Im gesamten Produktionsprozess werden keine Gabelstapler oder manuellen Lager mehr eingesetzt. Die Produktionslinien werden durch ein fahrerloses Transportsystem (FTS) automatisch mit Rohmaterialien bestückt. Am Ende jeder Endfertigungslinie befinden sich Palettierroboter, die Fertigwaren nach Kundenbestellung palettieren. Anschließend werden die Fertigwaren von den fahrerlosen Transportfahrzeugen abgeholt und in den Warenausgang transportiert, wo diese nach einem Haubenstretchverfahren⁷¹ entweder direkt versendet oder im vollautomatischen Hochregallager eingelagert werden.

⁷⁰ Vgl. Blechwarenfabrik Limburg GmbH (2021).

⁷¹ Bei einem Haubenstretchverfahren werden in diesem Anwendungsszenario lose palettierte Dosen oder Kanister mit einer Folie überzogen und somit für den Transport fixiert.



Abbildung 20: FTS bei der Bereitstellung von Rohmaterial und Fertigware

Eingelagerte Fertigwaren werden im Hochregallager in einem sogenannten chaotischen Verfahren vollautomatisch von Regalbediengeräten in den vier Gängen verteilt. Dies bedeutet, dass die Waren keinen eindeutig zugewiesenen Standort im Hochregallager haben, sondern von außen betrachtet zufällig in den Gängen verteilt werden. Lediglich Gitterboxen werden immer in den unteren Reihen gelagert, da diese ein hohes Gewicht aufweisen. Davon abgesehen orientiert sich die KI-gestützte Verteilung an verfügbarem Platz und der Minimierung der Fahrwege, die mittels einer Priorisierung im angewandten Algorithmus optimiert und an die fahrerlosen Transportfahrzeuge übermittelt werden.

Erfolgsfaktoren und Hemmnisse

Eine Herausforderung stellte die Priorisierung dar, da die Fertigung aus 15 unterschiedlich produzierenden Linien besteht, die fast alle mehrere Produkte fertigen können und unterschiedlich schnell produzieren. Dadurch entsteht eine immer wechselnde Grundlage, die das FTS beachten muss.

Die chaotische Lagerhaltung schützt das Unternehmen vor Lieferschwierigkeiten. Durch die wahllose Verteilung der Waren und unterschiedlichen Produkte im Hochregallager ist das Unternehmen zudem meist in der Lage, Ware zu liefern, auch wenn ein Regalgang ausfallen sollte.

Ergebnisse mit besonderem Bezug zur betrieblichen Ressourceneffizienz

Das Ergebnis der Umstellung auf vollautomatische Transporte und Lagerung im Gegensatz zu der manuellen Variante ist ein geordneter effizienter Prozess. Es treten weniger Transportschäden auf. Dies trägt in Kom-

ination mit allen weiteren optimierten Prozessen des neuen Standorts unter anderem dazu bei, dass jährlich rund 100 t Weißblech eingespart werden können. Des Weiteren wird die Unfallgefahr durch menschliches Versagen auf ein Minimum reduziert.

5.8 AS 8: Sustainability Analytics

Das ausgewählte Anwendungsbeispiel zu Sustainability Analytics in Abschnitt 5.8.1 bezieht sich auf eine durch maschinelles Lernen und Cloud-Technologien mögliche CO₂-Optimierung. Die Simulations- und Optimierungslösung ist erfolgreich in der Praxis bei einer gesamten Fahrzeugflotte umgesetzt worden. Dem betreffenden Unternehmen hat es geholfen, CO₂-relevante KPIs zu erfassen und vorherzusagen. So ist es auch möglich, das Unternehmen unter Berücksichtigung der CO₂-bezogenen gesetzlichen Anforderungen zu steuern. Untermauert wird dieses Anwendungsszenario durch zwei Praxisbeispiele. Ersteres präsentiert in Abschnitt 5.8.2 die von der juS.TECH AG durchgeführte Reduzierung des Ressourceneinsatzes durch intelligente Fahrzeugkoordination und zweiteres stellt in Abschnitt 5.8.3 die von der GEDIA Automotive Gruppe implementierte intelligente und bedarfsgerechte Auslastung des Druckluftsystems in der Produktion dar, das für nahezu alle Unternehmen des verarbeitenden Gewerbes von hoher Relevanz ist.

5.8.1 CO₂-relevante Optimierung mittels maschinellen Lernens und Cloud-Technologie

Das Streben nach nachhaltigen Wertschöpfungsketten ist längst auf der Agenda des Managements in der Automobilbranche angekommen. Treiber sind, wie in Abbildung 21, dargestellt, primär externe Faktoren wie Regularien, gesellschaftlicher Druck, Wettbewerb sowie Verschiebung der Marktnachfrage nach emissionsfreien Produkten. Doch auch interne Faktoren wie Unternehmenskultur und -strategie verstärken die Dringlichkeit, Wertschöpfungsketten nachhaltiger auszurichten⁷².

⁷² Vgl. Chin-Chun, H.; Tan, K. C.; Zailani, H. M. S. und Vaidyanathan, J. (2013).

Diese Entwicklung resultiert oftmals nicht nur in einer Verbesserung der Umweltwirkung der Unternehmung, sondern auch in einem signifikanten wirtschaftlichen Vorteil. Diese Wettbewerbsvorteile können erzielt werden, indem Nischenprodukte angeboten, Kosten eingespart und vor allem Risiken entlang der Wertschöpfungskette antizipiert werden, um eine nachhaltige Steuerung des Unternehmens zu ermöglichen.

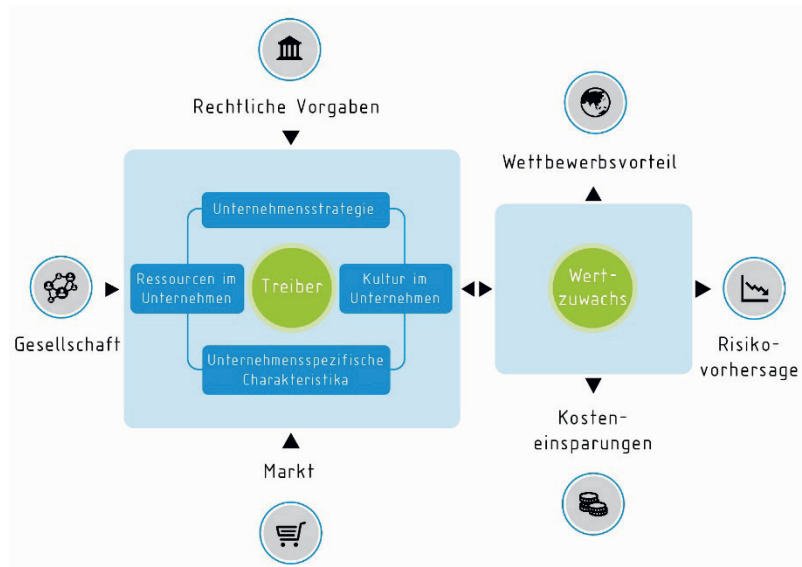


Abbildung 21: Interne und externe Einflussfaktoren auf nachhaltige Wertschöpfungsketten sowie deren Potenziale

Speziell im Automobilbereich wird die Nachhaltigkeit derzeit durch eine Reduktion von CO₂-Emissionen vorangetrieben. Die Europäische Union verhängt Strafzahlungen, sollten die CO₂-Emissionen der im europäischen Raum registrierten Fahrzeuge einen kritischen Schwellenwert überschreiten. Interessanterweise spielen die Emissionen bei der Herstellung der Fahrzeuge keine Rolle. Vielmehr werden durchschnittliche Verbräuche des einzelnen Fahrzeugs in der Nutzungsphase bei der Berechnung des Flottendurchschnitts zugrunde gelegt. Eine neue Herausforderung ist hierbei die Berücksichtigung von Emissionen in den etablierten Entscheidungsprozessen, die das Sammeln von Daten aus vielen Geschäftsbereichen erfordert. Marktnachfragen, Produktionskapazitäten und strategische Ziele der

Unternehmen (siehe Abbildung 22) müssen eine CO₂-optimierte Flottensteuerung mithilfe von KI zulassen⁷³.

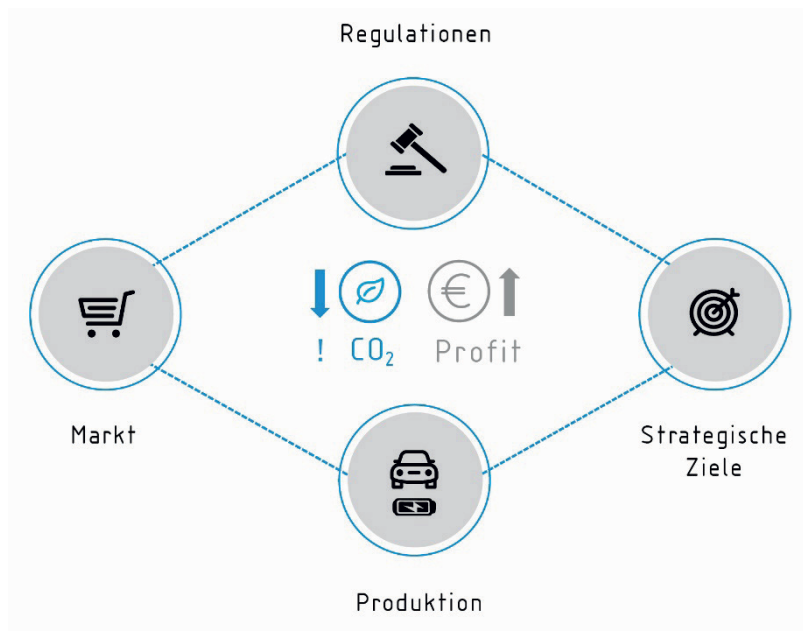


Abbildung 22: Facetten eines CO₂-Flottenoptimierungsszenarios

Damit eine zielgerichtete Steuerung der Flotte überhaupt möglich ist, müssen zukünftige Entwicklungen präzise vorausgesagt werden. Hierfür dienen üblicherweise historische Daten, die sich mithilfe von ML-Algorithmen in die Zukunft fortschreiben lassen. Bei Strafzahlungen sind jedoch externe Daten notwendig, da die Informationen über Zeitpunkt und Ort einer Fahrzeugregistrierung primär den Behörden der jeweiligen europäischen Länder obliegen. Die Gestaltung und Wahl eines geeigneten ML-Modells sind daher essenziell für die Präzision der Vorhersagen. Ein möglicher Lösungsansatz besteht darin (vgl. Abbildung 23), mithilfe von Klassifizierungs- und/oder Regressionsalgorithmen den zeitlichen Versatz zwischen einem

⁷³ Vgl. Deloitte Consulting GmbH (2021).

Referenzdatum der Lieferkette und dem tatsächlichen Registrierungsdatum bestmöglich abzuschätzen.

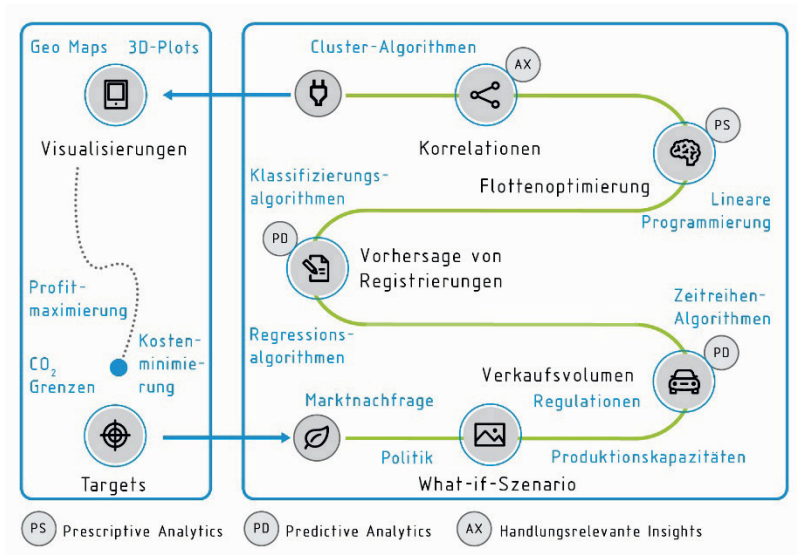


Abbildung 23: Anwendung von KI entlang einer Sustainability Analytics Lösung

Mithilfe dieser Vorhersagen und der Integration der gewonnenen Informationen mit unternehmensspezifischen KPIs sowie Produktionskapazitäten kann letztlich eine Flotte CO₂-optimiert gesteuert werden. Die für die technologische Umsetzung benötigten Faktoren werden in Tabelle 28 beschrieben.

Tabelle 28: Technologische Umsetzung von AS 8

Faktor	Beschreibung
Hardware	Es ist eine Infrastruktur notwendig, um die Daten aus den verschiedenen Geschäftsbereichen zu sammeln, externe Daten zu integrieren und auszuwerten. Hierbei können On-Premise-, Cloud- oder hybride Lösungen herangezogen werden.
Daten	Interne Daten werden aus bestehenden Planprozessen in Vertrieb und Produktion gesammelt und anschließend mit Finanzdaten integriert. Die Beschaffung der Information über registrierte Fahrzeuge erfolgt über externe Datenquellen. Die CO ₂ -Werte je Fahrzeug sind entweder als Stammdaten hinterlegt oder können mithilfe von fachlich abgegrenzten Anwendungsschnittstellen (APIs) approximiert und in die Verarbeitungsprozesse integriert werden.
KI-Methode	<p>Die Qualität der möglichen Erkenntnisse aus einer solchen Analytics-Lösung kann signifikant gesteigert werden, indem ML-Modelle bei der Ermittlung der Planzahlen sowie bei der Vorhersage zukünftiger Fahrzeugregistrierungen eingesetzt werden. Da die Qualität der Erkenntnisse mit der Zeit abnimmt, muss eine nahtlose Überführung in Handlungsempfehlungen realisiert werden. Hierbei können Cluster-Algorithmen unterstützen:</p> <p>Random Forest Algorithmus: Ein Random Forest (RF) kann sowohl bei Regressions- als auch Klassifikationsverfahren genutzt werden. RF kann herangezogen werden, um den Zeitpunkt einer Fahrzeugregistrierung vorauszusagen. Hierzu wird die Anzahl an Tagen abgeschätzt, die zwischen einem vorliegenden Referenzdatum und dem tatsächlichen Registrierungsdatum liegt. Die Voraussage der Ereignisse wird als quantitative Zielgröße definiert und gelöst.</p> <p>Auto ARIMA Algorithmus: Die geplanten Absatzzahlen im Vertrieb können initial mithilfe einer Zeitreihenanalyse in die Zukunft fortgeschrieben werden. Hierdurch können Markttrends oder saisonale Effekte automatisiert ausgewertet und als vorgeschlagene Werte am Anfang einer Simulation angenommen werden. Eine mögliche Zeitreihenanalyse ist der sogenannte „AutoRegressive Integrated Moving Average“ (ARIMA). Diese Zeitreihenanalysemethode ist sehr dynamisch, da die Wahl und die Parametrisierung des Modells durch vorläufige Testverfahren aus den Daten selbst ermittelt werden.</p> <p>K-Mean Algorithmus: Speziell bei komplexen Problemstellungen ist es wichtig, die Korrelationen zwischen den meist gegensätzlichen Zielgrößen zu verstehen und in entsprechende Handlungsempfehlungen zu überführen. Eine gängige Methode ist das Clustern von Daten in Abhängigkeit dieser unterschiedlichen Zielgrößen. Im Fall von Sustainability Analytics bedeutet dies, die Fahrzeuge hinsichtlich ihrer CO₂-Emissionen und Profitabilität in Cluster zu gruppieren. Hierbei müssen die Zielgrößen zunächst normiert werden, bevor sich Korrelationen bilden lassen. Mit dem K-Mean-Algorithmus können die Cluster automatisiert erstellt werden, da der Algorithmus in der Lage ist, diese für eine gegebene Anzahl von „K“ zu ermitteln. Dies hilft, um beispielsweise Fahrzeuge zu identifizieren, die den höchsten CO₂-Ausstoß bei gleichzeitig niedriger Profitabilität aufweisen und somit in ihrer Absatzzahl reduziert werden können.</p>
Wesentliche Arbeitsschritte	<ul style="list-style-type: none"> • Sammlung relevanter Daten • Datenaufbereitung • Modellevaluierung für die Vorhersage der Registrierungsdaten • Implementierung des selektierten Modells • Kontinuierliche Überwachung und Adjustierung des Modells

Die Komplexität besteht primär in der Datenintegration aus unterschiedlichen Planungsprozessen. Dabei müssen die Daten aus einer Aggregation harmonisiert werden, auf der eine CO₂-Besteuerung überhaupt möglich ist. Aspekte von Fahrzeugen, die für die CO₂-Besteuerung relevant sind, werden unter Umständen nicht im Vertrieb oder in der Produktion geplant. Dies macht die CO₂-optimierte Steuerung, als eine integrierte Lösung aus den unterschiedlichen Prozessen, noch vor dem eigentlichen Einsatz von KI zu einer Herausforderung der Datenharmonisierung. Tabelle 29 zeigt eine weitere Einschätzung der drei Bewertungskriterien „Implementierungsaufwand“, „Software und Hardwareaufwand“ und „Erforderliches Fachwissen“ auf.

Kritischer sind jedoch die Verfügbarkeit und Qualität der externen Daten. Daten zu Fahrzeugregistrierungen werden in den behördlichen Prozessen eines jeden Landes erhoben. Dabei gelten landesspezifische Restriktionen, welche dazu führen, dass die Daten nicht länderübergreifend in derselben Qualität vorliegen. Dies ist insbesondere bei der Prognose zukünftiger Ereignisse kritisch. Das Random-Forest-Modell muss mit tatsächlichen Fahrzeugregistrierungen trainiert werden, damit es überhaupt in der Lage ist, verlässliche Prognosen zu erstellen. Die Qualität der externen Daten ist daher mitunter am kritischsten für den erfolgreichen Einsatz der KI.

Tabelle 29: Aufwandseinschätzung für AS 8

Bewertungskriterium	Aufwand	Beschreibung
Implementierungsaufwand	hoch	Für die Erstellung eines „Minimum Viable Product“ (MVP) ist bereits mit einem Implementierungsaufwand von drei bis vier Monaten zu rechnen.
Software und Hardwareaufwand	mittel	Die Evaluierung der Modelle kann flexibel über Cloud-Analytics-Lösungen wie den Azure ML Service erfolgen. Die tatsächliche Implementierung des Modells wird je nach IT-Strategie entweder über Cloud Analytics Lösungen selbst oder innerhalb der On-Premise-Lösung wie beispielsweise der Predictive Analytics Library in SAP HANA vollzogen.
Erforderliches Fachwissen	hoch	Aufgrund der prozessübergreifenden Lösung ist ein ebenso übergreifendes Verständnis der Geschäftsprozesse sowie der darin anfallenden Daten notwendig. Gerade in großen Konzernen ist dieses Wissen meist nicht vorhanden. Zudem muss speziell bei der Erstellung des ML-Modells statistisches Wissen mit dem Fachwissen kombiniert werden, damit neben der Gewinnung neuer Erkenntnisse diese auch interpretiert und erklärt werden können.

Die erfolgreiche Steuerung der Flotten hin zu einem CO₂-reduzierten Portfolio ist wesentlich von der Genauigkeit der Prognosen zu zukünftigen Ereignissen wie den zu erwartenden Fahrzeugregistrierungen abhängig. Retrospektiv kann diese Genauigkeit mithilfe von KI mehr als verdoppelt werden. Als Grundlage für die Messung der Genauigkeit wird in diesem Fall der Mean Average Error hinsichtlich des tatsächlichen Registrierungsdatums gegenüber dem angenommenen bzw. vorhergesagten Registrierungsdatum herangezogen. Werden die Ziele wie geplant erreicht, kann damit in den nächsten Jahren der CO₂-Ausstoß der hergestellten Fahrzeuge um mehr als ein Drittel gesenkt werden (siehe Tabelle 30).

Tabelle 30: Auswirkungen auf die Ressourceneffizienz von AS 8 anhand des Kennzahlenmodells

Ressource	Einfluss	Kennzahlen & Beschreibung
Material	kein Einfluss	
Elektrische Energie	kein Einfluss	
Wasser	kein Einfluss	
CO ₂ -Emissionen	hoch	Laut neuesten Studien müssen die Automobilhersteller die CO ₂ -Emissionen ihrer im europäischen Raum registrierten Fahrzeuge um ca. 38 % reduzieren, damit die Zielvorgaben eingehalten werden können. Da die Strafzahlungen signifikant hoch sind, kann davon ausgegangen werden, dass Unternehmen mithilfe von Sustainability-Analytics-Lösungen diese CO ₂ -Reduktion im Einklang mit den Unternehmenszielen erreichen können. Insgesamt sind somit potenzielle Einsparungen im hohen Maße realistisch.
Andere Effekte	–	keine

5.8.2 Praxisbeispiel AS 8: juS.TECH AG

Reduzierung des Ressourceneinsatzes durch intelligente Fahrzeugkoordination

Vorstellung der juS.TECH AG

Die juS.TECH AG aus Uelzen ist eine Unternehmensberatung und entwickelt Anwendungen im Feld der künstlichen Intelligenz mit Fokus auf nachhaltiger Digitalisierung. Als Schwerpunkt werden Use-Cases in kleinen und mittelständischen Unternehmen identifiziert, die mit wenig Mitteln einen großen Nutzen erzielen. Dem Unternehmen angeschlossen ist das juS.TECH Institut, welches Transferforschung im Gebiet der Digitalisierung betreibt, um den Wandel hin in ein neues digitales Zeitalter von Beginn an nachhaltig zu gestalten.⁷⁴



Herausforderungen des Kunden

Das folgende Praxisbeispiel betrachtet eine Logistikanwendung, die eine Senkung des Ressourceneinsatzes (in Form von Kraftstoff) durch die intelligente Koordinierung der Fahrzeuge auf dem Weg zu einer Logistik-Hauptumschlagsbasis fokussiert. Im vorliegenden Beispiel können die Fahrzeuge aufgrund baulicher Gründe oder zu langer Wegstrecken nur bestimmte Rampen anfahren. Daher kann es vor einzelnen Rampen zu Staus kommen. Dies ist sehr zeit- und kostenintensiv.

Die besondere Herausforderung besteht darin, dass viele komplexe Vorgänge unter vielen verschiedenen Aspekten in einer sehr hohen Geschwindigkeit abgewogen werden müssen. Menschen stoßen hier aufgrund der Komplexität schnell an kognitive Grenzen. Die Planung der LKW muss demnach agil erfolgen, da Umweltfaktoren wie Staus, Pannen und Frachtkontrollen zu permanenten Störungen des geplanten Betriebsablaufes führen. Ein starrer Prozess oder eine lange Planung im Voraus ist deshalb nicht zielführend.

⁷⁴ Vgl. juS.TECH AG (2021).

Lösungen durch den Einsatz von KI

Zur Lösung dieser Problemstellung ist von juS.TECH ein Modell entwickelt worden, das komplexe Zusammenhänge in den Daten erkennt und Anwendern die Betrachtung spezifischer Zeiträume ermöglicht. Dieses Modell basiert auf den Methoden des Deep Learnings und wird durch erweiterte Zeitreihendaten (engl. „Time Series Data Augmentation“) stetig trainiert. Um auch Bilddaten in die Lösung mit einzubeziehen, werden Computer-Vision-Ansätze genutzt, die unter anderem erzeugende gegnerische Netzwerke (engl. „Generative Adversarial Networks“) verwenden. Im ersten Schritt sind dabei zur Modellerstellung alle möglichen Datenquellen untersucht worden. Daten, die in diesem Fallbeispiel vorliegen, sind:

- die Darstellung der LKW-Flotte in Echtzeit,
- die Kameraüberwachung des Werksgeländes (Sicherheit),
- das Indoor-GPS zum Tracking von Ladung und Logistikfahrzeugen,
- die Planungsübersicht der Laderampen und
- die Übersicht der Container-Bereitstellungsfahrzeuge.

Mithilfe der bereits vorhandenen Daten kann ein erster Proof of Concept erstellt werden. Dabei werden die verfügbaren Daten zentral auf einem Green-Cloud-Server⁷⁵ zusammengeführt.

Weitere Daten, die zur Verbesserung der Genauigkeit genutzt werden, sind digitale Frachtpapiere. Hier ist es ausreichend, diese erst bei der Einfahrt des LKWs zu scannen. Dabei werden im ersten Schritt mithilfe der Kameraüberwachung die tatsächlichen Fahrwege, Rangierflächen und Ladevorgänge digital sichtbar gemacht. Durch die Abgabe der Ladepapiere bei der Einfahrt auf das Gelände wird eine Prognose erstellt, wie lange der LKW eine Rampe blockieren wird. Die Ressourceneinsparung basiert

⁷⁵ Konzept, welches auf die ökologischen Vorteile des Konsums von IT-Diensten über das Internet abzielt

darauf, dass im Prozess auftretende Störungen verringert werden. Die größte Störung für die Verspätung von LKW sind Autobahnstaus. Der entscheidende Datenpunkt im Prozess ist die tatsächliche Freigabe der Rampe für den nächsten LKW. Das heißt, dass der abfahrende LKW bereits die Rangierfläche verlassen hat und auch kein weiteres Fahrzeug die Rangierfläche belegen wird.

Mithilfe dieses Wertes können anschließend die nachfolgenden anfahrenden LKW gesteuert werden. Sollte es zu Verzögerungen im tatsächlichen Ablauf kommen, die sich durch den Vergleich zur vorliegenden Planung erkennen lassen, so wird den folgenden Fahrzeugen eine eigens berechnete Durchschnittsgeschwindigkeit empfohlen. Dadurch kann nicht nur der Verbrauch während der Fahrt gesenkt werden, es entfallen auch die Wartezeiten vor dem Logistik-Hub. Besonders bei gekühlter Fracht führen Standzeiten zu einem deutlich erhöhten Ressourcenverbrauch.

Erfolgsfaktoren und Hemmnisse

Die Umsetzungsschwierigkeit eines KI-gestützten Lösungsansatzes liegt oft in den hohen Entwicklungskosten für ein einzelnes mittelständisches Unternehmen. Gleichzeitig ist das Wissen über mögliche Use-Cases noch nicht in der breiten Masse der Unternehmen angekommen. Ein weiterer Faktor betrifft die mangelnde Prozessinfrastruktur im herkömmlichen Betrieb sowie den unachtsamen Umgang mit Daten. Dies führt dazu, dass digitale Prozesse häufig keinen Mehrwert liefern, weil die herkömmlichen Prozesse schon mangelhaft sind.

In diesem konkreten Projekt spielt das Thema Changemanagement eine entscheidende Rolle. Die Berufsgruppen der Berufskraftfahrer/innen sowie Disponent/innen werden in ihrer eigenen Entscheidungsfreiheit durch KI-gestützte Empfehlungen beschränkt. Es kann leicht der Eindruck entstehen, dass die Arbeitsqualität, Verantwortung und Erfahrung der einzelnen Personen an Bedeutung verlieren.

Ergebnisse mit besonderem Bezug zur betrieblichen Ressourceneffizienz

Mithilfe der aufgezeigten Lösung kann an Tagen mit besonders vielen Störfällen eine Ressourceneinsparung von bis zu 20 % realisiert werden.

Da es sich bei Kraftstoff um einen teuren Betriebsstoff handelt, wird nicht nur ein positiver Beitrag zur THG-Bilanz geleistet, sondern es werden auch die Kosten gesenkt. Weitere Ressourceneinsparungen, die sich beiläufig ergeben, sind der verringerte Papierverbrauch, gesunkene Leerfahrten von Bereitstellungsfahrzeugen im Bereich der Container, weniger Rangierschäden an Fahrzeugen sowie ein gesunkener Energieverbrauch der in der Halle befindlichen Logistikfahrzeuge. Durch den Einsatz von Green-Cloud-Lösungen ist die THG-Bilanz auch bei steigender Datenmenge konstant.

juS.TECH arbeitet mit starken Partnern in Deutschland zusammen. So ist es möglich, die gesamte digitale Infrastruktur treibhausgasneutral zu hosten und dabei von europäischen Datenschutzrichtlinien zu profitieren. Da Clouds zunehmend an Bedeutung gewinnen, ist insbesondere das Thema Green-Cloud ein Ergebnis der Bemühungen rund um die betriebliche Ressourceneffizienz – ökologisch, ökonomisch und sozial.

5.8.3 Praxisbeispiel AS 8: GEDIA Automotive Gruppe

Intelligente und bedarfsgerechte Auslastung des Druckluftsystems in der Produktion

Vorstellung der GEDIA Automotive Gruppe

Die GEDIA Automotive Gruppe besteht seit über 100 Jahren und produziert seit 1955 Karosserieteile und Schweißbaugruppen für die Automobilindustrie in der ganzen Welt. Heute beschäftigt das Unternehmen mehr als 4.300 Mitarbeitende an acht Produktionsstätten und ist an Joint Venture- und Forschungsunternehmen beteiligt. Um eine fortlaufende Optimierung des Produktionsbetriebs sicherzustellen, sind an allen relevanten Knotenpunkten im Unternehmen Messsysteme zur Datenerfassung implementiert. Das folgende Praxisbeispiel beleuchtet die datenge-



triebene Optimierung des Druckluftsystems am Hauptproduktionsstandort in Attendorf.⁷⁶

Herausforderungen des Kunden

Druckluft ist ein wichtiger Energieträger, der in etwa 70 % aller Industriebereiche zum Einsatz kommt. Gleichzeitig ist Druckluft teuer und energieaufwendig in der Erzeugung und damit ein relevanter Kostenfaktor in der Produktion. Ein Hindernis bei der Optimierung des Druckluftsystems für GEDIA ist der dezentralisierte Hauptstandort in Attendorf mit sechs Werken. So sind vier unterschiedliche Typen von Kompressorstationen entstanden. Die zwingend erforderlichen Stand-by- bzw. Leerlaufkosten der Kompressoren zur Vermeidung eines Defekts verschwenden Energie und sind wirtschaftlich ineffizient. Ferner hat GEDIA festgestellt, dass zu hohe Herstellerangaben für die Reservedruckluft bezüglich der Produktionsmaschinen zu unnötigen Überkapazitäten des Druckluftsystems führen.

Lösung durch den Einsatz von KI

Nachdem eine übergeordnete Steuerung des Kompressor-Herstellers (Kaeser Kompressoren SE) auf den Markt gebracht wurde, hat GEDIA dies als Startpunkt zur Optimierung des kompletten Systems genommen. Basierend darauf werden Messpunkte zur genauen Ermittlung der Verbrauchs- und Druckwerte zur Gewährleistung eines stabil bleibenden Luftdrucks für die Maschinen gesetzt. Dabei werden sämtliche Volumenströme gemessen, die wiederum über einen Mess- bzw. Zeitraum detaillierte Aussagen darüber zulassen, ob ein Kompressor effizient betrieben wird. Ein daraus resultierendes Ergebnis sind der Umbau einer Kompressorstation, der Abbau zweier großer Kompressoren sowie der Einbau eines kleinen Kompressors, der beispielsweise über das Wochenende bei weniger Betrieb die Arbeit der großen Kompressoren ersetzt.

Darüber hinaus konnten die Herstellerangaben der benötigten Druckluft für die jeweiligen Maschinen neu bewertet werden. Hierbei hat GEDIA eine Reduzierung des Drucks am Netz bis zu einem Punkt vorgenom-

⁷⁶ Vgl. GEDIA Automotive Group (2021).

men, an dem noch sicher produziert werden kann. In Zahlen gesprochen heißt dies, dass durch den Verzicht auf theoretische Reserveangaben das Netz mit 6,5 bar anstelle von 7,5 bar betrieben wird. Durch diese klein erscheinende Differenz kann eine große Menge an Energie eingespart werden. Möglich ist dies durch die intelligente Steuerung des Druckluftangebots mittels eines adaptiven 3-D-advanced-Algorithmus⁷⁷ basierend auf den Verbrauchs- und Druckmessungen an den implementierten Messpunkten. Dabei werden auch Schalt- und Regelverluste, Druckflexibilität, Betrieb am Frequenzumrichter und Verluste im Leerlaufbetrieb in das Optimierungsverfahren mit einberechnet. Anschließend wird das erreichbare mögliche Optimum simuliert und die jeweiligen Kompressoren werden angesteuert, wobei der Bedarfsdruck maßgebend ist.

Erfolgsfaktoren und Hemmnisse

Zu den mit Abstand größten Erfolgsfaktoren zählt die erfolgreiche Etablierung eines umfangreichen Daten-Messsystems im Unternehmen. An allen relevanten Knotenpunkten sind Sensoren implementiert und messen unter anderem Energieflüsse und -verluste sowie Leerläufe. Erst diese Datenmessung und -nutzung ermöglichen die Optimierung des Druckluftsystems im ganzen Unternehmen. Positive Erfahrungen aus erfolgreich umgesetzten Projekten der Vergangenheit erleichtern die Freigabe von Budgets für zukünftige Projekte.

Dennoch bleibt die interne Finanzierung ein Hemmnis für entsprechende Anwendungsszenarien. Es kann passieren, dass nach Implementierung eines neuen Systems – beispielsweise eines neuen Druckluftsystems – die Fehlerursache bei Maschinenausfällen immer genau in diesem neuen System gesehen wird. Es muss eine generelle Akzeptanz für entsprechende Neuerungen in der ganzen Belegschaft geschaffen werden, um neue Systeme optimal nutzen und verbessern zu können.

⁷⁷ Vgl. KAESER KOMPRESSOREN SE (2019).

Ergebnisse mit besonderem Bezug zur betrieblichen Ressourceneffizienz

Die Ressourceneinsparung ist primärer Grund, weshalb sich GEDIA für die Implementierung eines neuen Druckluftsystems entschieden hat. Die sich ergebenden tatsächlichen Einsparungen zielen auf die Ressource Druckluft und die Energiequelle Strom ab. Um standortübergreifend und gruppenweit vergleichbare Daten zu erlangen, wurde ein Benchmark-Strompreis zugrunde gelegt. Vor der Implementierung beliefen sich die internen Kosten pro 1000 m³ Druckluft auf 17 €. Aktuell liegen sie lediglich bei 11 € bei einer Stromeinsparung von über 35 %.

6 HEMMNISSE UND ERFOLGSFAKTOREN FÜR DIE ANWENDUNG VON KI

Im Folgenden werden die identifizierten Hemmnisse und Erfolgsfaktoren aufgezeigt, welche sowohl aus Ergebnissen der Literaturrecherche als auch aus der Analyse der Anwendungsszenarien und Praxisbeispiele entstammen. Die Hemmnisse stützen sich zudem auf die Expertenbefragung in Kapitel 3.

6.1 Hemmnisse

Mögliche Hemmnisse wurden in der durchgeführten Umfrage (vgl. Kapitel 3) von zwei unterschiedlichen Gruppen von Teilnehmenden abgefragt. Zum einen waren dies Unternehmen, die KI (bislang) nicht einsetzen (Gruppe 1). Hierunter fallen sowohl Unternehmen, welche die Einführung von KI planen, als auch solche, die es auch in Zukunft nicht vorhaben. Zum anderen wurden Unternehmen befragt, die KI bereits eingeführt haben (Gruppe 2). Dabei wurden elf potenzielle Hemmnisse vorgegeben sowie die zusätzliche Antwortmöglichkeit „Sonstige“ angeführt, um individuelle Hemmnisse abbilden zu können. Aus den zur Verfügung stehenden Antwortmöglichkeiten sollten die Teilnehmenden drei Antworten mit der größten Relevanz für das eigene Unternehmen auswählen. Abbildung 24 stellt die Ergebnisse der Umfrage dar. Dabei wird auf der x-Achse der Anteil der Unternehmen aufgetragen, die die jeweils aufgeführte Herausforderung als eines der drei relevantesten Hemmnisse empfinden.

Obwohl sich die Prozentsätze je Hemmnis zwischen den beiden analysierten Gruppen zum Teil unterscheiden, sind einige Gemeinsamkeiten erkennbar. So werden in beiden Gruppen die „fehlende Datengrundlage“, das „fehlende Know-how“ und ein „hoher Implementierungsaufwand“ jeweils von über 30 % der Unternehmen als eines der größten Hemmnisse gesehen. Ebenfalls von beiden Gruppen als relevant eingestuft wurden die „mangelnde technische Infrastruktur“, die „Schwierigkeit, geeignete Technologien zu identifizieren“, sowie der „Mangel an Unterstützung durch die Unternehmensführung“. Auch die „unklare Definition von KI“ stellt insbesondere für Unternehmen, die KI (noch) nicht einsetzen, ein Hemmnis dar.

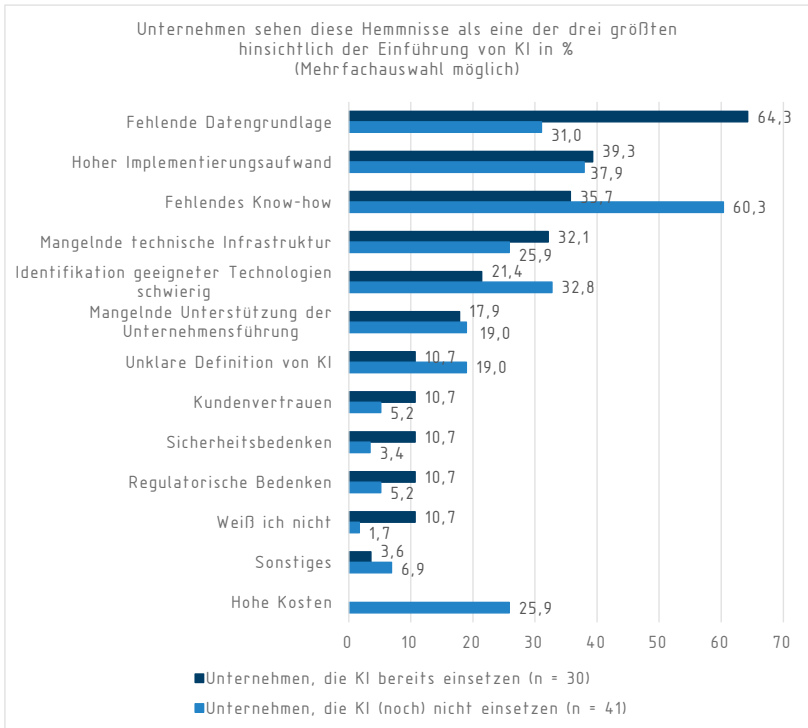


Abbildung 24: Hemmnisse für den Einsatz von KI

Es sind jedoch auch deutliche Unterschiede zwischen den beiden Gruppen zu beobachten. Während die meisten Unternehmen ohne KI-Erfahrungen fehlendes Fachwissen als eines der drei größten Hemmnisse angeben, sehen Unternehmen mit KI-Erfahrungen die fehlende Datengrundlage als größtes Hemmnis. Wie in Abschnitt 3.3 dargestellt, bezieht jedoch eine Vielzahl der Unternehmen, die KI-Lösungen implementiert haben, das notwendige Fachwissen von externen Dienstleistern. Die fehlende Datengrundlage wird erst bei näherer Auseinandersetzung mit dem Thema KI als Hemmnis wahrgenommen. Außerdem fällt auf, dass kein einziges Unternehmen mit KI-Erfahrung hohe Kosten als Hemmnis angibt, während innerhalb der Gruppe 1 über 25 % der befragten Unternehmen diese als relevantes Hemmnis ansehen. Eine mögliche Erklärung ist, dass Unternehmen ohne Erfahrung im Bereich KI die Kosten zur Einführung eher überschätzen.

Der mögliche Verlust von Kundenvertrauen, etwaige Sicherheitsbedenken sowie Bedenken hinsichtlich regulatorischer Konformität durch die Einführung von KI spielen bei beiden Gruppen eine eher untergeordnete Rolle. Sonstige Hemmnisse, die von den befragten Unternehmen benannt wurden, betreffen zum einen eine zu hohe Erwartungshaltung des Managements in Bezug auf die Skalierbarkeit von KI-Anwendungen. Dies betrifft vor allem den Rollout von Pilotanwendungen in der breiten Anwendung. Zum anderen müssen KI-Anwendungen in alle Prozessschritte eingebettet werden können, um die damit verbundenen Vorteile vollständig ausschöpfen zu können.

Abbildung 25 fasst sämtliche Erkenntnisse der Umfrageauswertung, Expertenbefragung sowie der Literaturrecherche zusammen. Aufgeteilt auf die sechs vordefinierten Kategorien (technologisch, ökologisch, regulatorisch, sozial, unternehmensstrategisch und ökonomisch) wurden insgesamt 20 potenzielle Hemmnisse für die Einführung von KI im betrieblichen Umfeld identifiziert. Hemmnisse, die sowohl in der Umfrage als auch in den Ergebnissen der detaillierten Literaturrecherche Erwähnung finden, sind entsprechend fett markiert und gelten somit als höher priorisiert als diejenigen, die ausschließlich durch Recherche identifiziert wurden.



Abbildung 25: Identifizierte Hemmnisse für die Einführung von KI

Tabelle 31 gibt die technologischen, ökologischen, ökonomischen und sozialen Hemmnisse für den Einsatz von KI wieder.

Tabelle 31: Beschreibung von technologischen, ökologischen, ökonomischen und sozialen Hemmnissen für den Einsatz von KI

Hemmnis	Beschreibung
	Technologisch
Fehlende Datenbasis	Unzureichende Datenverfügbarkeit oder schlechte Datenqualität ist ein häufiges Problem im industriellen Umfeld. Einige Unternehmen verfügen zwar über die relevanten Datensätze, können sie aber nicht jederzeit und in gewünschter Form abrufen. Zudem besteht die Schwierigkeit, einen umfassenden Überblick über die eigens produzierte Datenmenge zu behalten. Unvollständige und nicht gekennzeichnete Daten können den Einsatz künstlicher Intelligenz erschweren. Je nach Ausmaß der Datenproblematik kann die Implementierung von KI-Lösungen gar gänzlich verhindert werden. Die Datenqualität kann durch diverse Fehlerarten beeinträchtigt werden. Dazu zählen z. B. Dopplungen, Rechtschreibfehler und Fehlinformationen. Eine fehlende Annotation der Daten verhindert zudem bei überwachten Algorithmen das Training eines Systems. ^{78,79,80,81}
Hoher Implementierungsaufwand	Insbesondere komplexe Problemstellungen, die nicht mit vorhandenen Lösungen angenähert werden können, zeichnen sich z. T. durch einen hohen Implementierungsaufwand aus. Die Einführung von KI kann in solchen Fällen ein langfristiges Unterfangen sein. Verstärkt wird dieser Umstand durch unternehmensweite statt streng abgesteckte Anwendungsfälle. Potenziell notwendige ergänzende Änderungen unternehmensorganisatorischer Art können zu weiteren signifikanten Verzögerungen führen. ^{82,83}
Mangelnde technische Infrastruktur	Schlechte technische Infrastruktur wird als relevantes Hemmnis wahrgenommen. Dies betrifft beispielsweise langsame Internetverbindungen bzw. einen schlechten Netzausbau und fehlende Anbindungen von Produktionsmaschinen an eine zentrale oder gar dezentrale Plattform. Insbesondere fehlende oder mangelhafte Netzabdeckung, die keinen verlässlichen Datenaustausch ermöglicht, verhindert KI-Anwendungen, die auf Datenzugriff in Echtzeit angewiesen sind. ^{84,85}
Unklare Definition des Begriffs „KI“	Vor allem in kleinen und mittleren Unternehmen existiert oft eine weitreichende Unkenntnis oder falsche Auffassung von KI. Entsprechend werden KI-Lösungen z. T. als uninteressant für die eigene Geschäftstätigkeit wahrgenommen. Einige Unternehmen sehen KI im Kontext der Digitalisierung als zusätzliche Herausforderung statt als hilfreiche neue Technologie. Die empfundene Bedrohung bestehender Geschäftsmodelle durch den Einsatz von KI fördert eher die Wahrnehmung als Risiko denn als Chance. Folglich findet derzeit eine unzureichende bzw. schwer nachvollziehbare Kommunikation der Möglichkeiten von KI im industriellen Umfeld statt. ⁸⁶

⁷⁸ Vgl. Weichenthal, S.; Hatzopoulou, M. und Brauer, M. (2019).

⁷⁹ Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).

⁸⁰ Vgl. Wangermann, T. (2020).

⁸¹ Vgl. Lundborg, M. und Märkel, C. (2019).

⁸² Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).

⁸³ Vgl. Brynjolfsson, E.; Rock, D. und Syverson, C. (2017).

⁸⁴ Vgl. Wangermann, T. (2020).

⁸⁵ Vgl. Lundborg, M. und Märkel, C. (2019).

⁸⁶ Vgl. Wangermann, T. (2020).

Hemmnis	Beschreibung
Intransparenz der verwendeten Methoden und Ergebnisse	Sowohl für fachfremde Personen als auch Fachleute ist die Arbeitsweise von KI zum Teil nicht nachvollziehbar. Abhängig von KI-Methode und verwendetem Algorithmus wird oftmals der Lösungsweg zur Schlussfolgerung nicht dokumentiert. Ein Rückschluss auf mögliche Fehler bzw. eine manuelle Überprüfung des ausgegebenen Ergebnisses ist bei diesen sogenannten Blackbox-Algorithmen meist nicht möglich. Diese fehlende Transparenz schreckt Anwendende von einer Implementierung ab, da KI mit einem Verlust an Kontrolle bzw. Transparenz verbunden wird. ⁸⁷
Ökologisch	
Bisher geringe Erforschung des ökologischen Einflusses von KI	Der derzeitige Stand der Forschung bezüglich der potenziellen Auswirkungen von KI-Lösungen auf die ökologische Performance eines Unternehmens ist noch überschaubar. Bisher befassen sich vergleichsweise wenig wissenschaftliche Veröffentlichungen mit dem Thema. Dies wirkt als Hemmnis für Unternehmen, die eine Verringerung des ökologischen Einflusses als Treiber für die Einführung von KI sehen. ⁸⁸
Verursachung hoher THG-Emissionen bei der Entwicklung von KI-Methoden	Das Training eines KI-Modells kann Studien zufolge bis zu 300.000 kg CO ₂ -Äquivalent emittieren ⁸⁹ . Dies entspricht in etwa dem Ausstoß von fünf PKW über ihren gesamten Produktlebensweg hinweg. Dies lässt sich auf große Energieverbräuche in Datenzentren und Serverfarmen zurückführen. Für Unternehmen, die großen Wert auf Umweltschutz legen, kann dies ein großes Hemmnis sein, weiter in KI zu investieren – insbesondere wenn die gleichzeitige ökologische Optimierung in der eigenen Geschäftstätigkeit nicht klar zu quantifizieren bzw. vorherzusagen ist (vgl. „Bisher geringe Erforschung des ökologischen Einflusses von KI“). ^{90,91}
Trade-offs zwischen ökonomischen und ökologischen Zielen	In manchen Fällen steht der ökonomische Aspekt in Konflikt mit dem ökologischen Ziel. Zum Teil sind ökologisch sinnvolle Maßnahmen höher bepreist als solche, die einen rein ökonomischen Fokus aufweisen. In solchen Fällen muss abgewogen werden, welcher Faktor für das Unternehmen der relevantere ist. Entsprechend muss auch die implementierte KI für solche Entscheidungsprobleme trainiert werden. ⁹²
Ökonomisch	
Verlust von Kundenvertrauen	Die Unsicherheit und Unkenntnis bzgl. KI in der Bevölkerung bzw. bei der potenziellen Kundschaft gelten als Hemmnis, da einige Unternehmen bei einer Einführung von KI in die eigenen Geschäftsprozesse einen Verlust von Kundenvertrauen als möglich erachten. Entsprechend würde sich künstliche Intelligenz direkt und negativ auf die ökonomische Geschäftstätigkeit auswirken. Die Aussage basiert auf einer Umfrage bei Unternehmen. Ein kausaler Zusammenhang zwischen implementierter KI und Kundenvertrauen ist somit nicht wissenschaftlich nachgewiesen. ⁹³

⁸⁷ Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).

⁸⁸ Vgl. Chen, H. (2019).

⁸⁹ Vgl. Mathur, D.; Ahmad, Z. und Chamuah, A. (2020).

⁹⁰ Vgl. Vinuesa, R.; Azizpour, H.; Leite, I.; Balaam, M.; Dignum, V.; Domisch, S.; Felländer, A.; Langhans, S. D.; Tegmark, M. und Fuso Nerini, F. (2020).

⁹¹ Vgl. Jones, N. (2018).

⁹² Vgl. Mathur, D.; Ahmad, Z. und Chamuah, A. (2020).

⁹³ Vgl. Wangermann, T. (2020).

Hemmnis	Beschreibung
Hohe Kosten	Ein als hoch wahrgenommener Implementierungsaufwand schlägt sich oftmals in hohen Kosten nieder. Hierbei besteht die Verbindung zu vorab genannten Hemmnissen. So führen sowohl die mangelnde technische Infrastruktur als auch schlechte oder fehlende Daten zu einer signifikanten Erhöhung der Implementierungskosten. Konträr dazu nutzen viele Lösungen Open-Source-Technologien. So können kleine Projekte oftmals kostengünstig umgesetzt werden. In vielen Fällen sind KI-Implementierungen daher weniger eine Frage des Finanziellen als eher des Vertrauens in die Sinnhaftigkeit und Wirtschaftlichkeit der Lösungen. ⁹⁴
Sozial	
Fehlendes Know-how	Fehlendes Fachwissen ist eines der größten Hemmnisse für Unternehmen bei der Einführung von KI. Oft ist das benötigte Wissen im Unternehmen nicht vorhanden. Zusätzlich sind die erforderlichen Informationen für Unternehmen meist nicht direkt verfügbar, da viele Anwendung noch Teil der Forschung oder nicht ohne weiteres auf ihren Anwendungsfall übertragbar sind. Mangelndes Verständnis um die Funktionsweise der eingeführte KI-Systeme resultiert in Unsicherheit gegenüber der neuen Technologie. Hieraus entstehende Bedenken von Entscheidungsträgern im verarbeitenden Gewerbe verhindern oftmals eine aktive Auseinandersetzung mit der Technologie und entsprechend die Implementierung von KI-Lösungen. Schulungs- und Informationsangebote können hierbei zur Sensibilisierung beitragen und entsprechende Befangenheiten abbauen. ^{95,96,97,98}

⁹⁴ Vgl. Lundborg, M. und Märkel, C. (2019).

⁹⁵ Vgl. Chen, H. (2019).

⁹⁶ Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).

⁹⁷ Vgl. Wangermann, T. (2020).

⁹⁸ Vgl. Lundborg, M. und Märkel, C. (2019).

6.2 Erfolgsfaktoren

Neben Hemmnissen wurden während der Literaturrecherche auch Erfolgsfaktoren identifiziert, die eine Implementierung von KI-Lösungen unterstützen bzw. vereinfachen. Diese können in die vier Kategorien soziale, technologische, unternehmensstrategische und regulatorische Faktoren eingeteilt werden (siehe Abbildung 26). Zudem wurden während der Gespräche bezüglich der in Kapitel 5 beschriebenen spezifischen Praxisbeispiele Enabler abgefragt. Entsprechende Überschneidungen mit den Ergebnissen der Literaturrecherche sind in Abbildung 26 fett markiert.

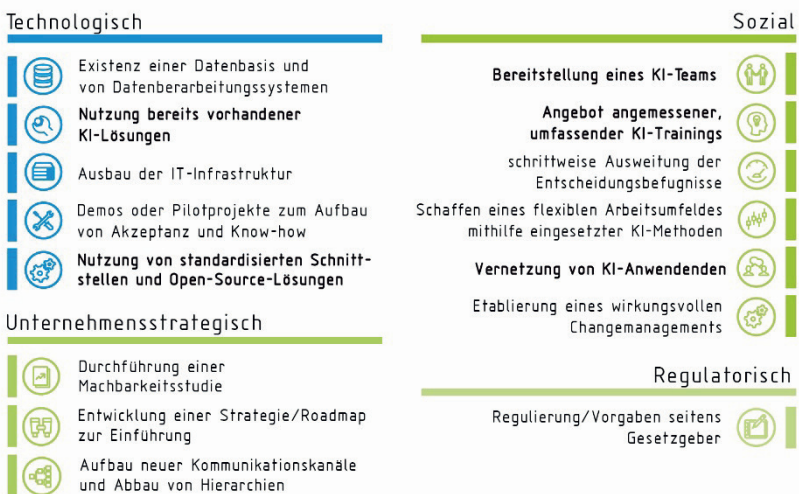


Abbildung 26: Identifizierte Erfolgsfaktoren für die Einführung von KI

Zudem wurden zwei weitere Erfolgsfaktoren genannt, die anhand veröffentlichter Literatur nicht identifiziert werden konnten (Machbarkeitsstudie, Changemanagement). Nachfolgende Tabelle 32 beschreibt zusammengefasst sämtliche Erfolgsfaktoren und dient als erster Einstieg in einen ziel-führenden Wissenstransfer für interessierte Unternehmen.

Tabelle 32: Beschreibung von technologischen, strategischen, sozialen und regulatorischen Erfolgsfaktoren für den Einsatz von KI

Erfolgsfaktoren	Beschreibung
<p>Existenz einer Datenbasis und von Datenverarbeitungssystemen</p>	<p style="text-align: center;">Technologisch</p> <p>Unternehmen mit Vorkenntnissen im Bereich Big Data oder solche, die bereits seit einiger Zeit viele ihrer firmeninternen Daten sammeln, haben große Vorteile gegenüber Unternehmen, welche nicht auf eine bestehende Datenbasis zugreifen können. Ein erster Schritt für Unternehmen in Richtung KI ist daher oft, Methoden zur Datensammlung und Datengewinnung zu implementieren und eine Verbesserung interner Abläufe zur Weitergabe dieser Daten zu entwickeln. Weiterhin ist zu prüfen, in welcher Form die Daten vorliegen und ob sie verarbeitet werden können.^{99,100,101}</p>
<p>Nutzung bereits vorhandener KI-Lösungen</p>	<p>Insbesondere bei leicht zu implementierenden Anwendungsfällen, die bereits hinreichend erforscht sind, kann oft sehr schnell eine kostengünstige und geeignete Technologie zur Lösung des Problems gefunden werden. Zudem ist es oft möglich, bereits vorhandene Schnittstellen oder KI-Anwendungen anderer Unternehmen wie beispielsweise Chat-Bots in das eigene Unternehmen zu integrieren. Dies schafft Akzeptanz und unterstützt beim Aufbau erster Schnittstellen mit dem Thema. Zudem verringert sich der Implementierungsaufwand signifikant. Ebenfalls ermöglichen existierende KI-Lösungen z. T. Implementierungen nach dem Baukastenprinzip. Entsprechend wird ein zielgerichteter und kostengünstiger Einsatz geboten (vgl. Abschnitt 5.2.2). Die Nutzung etablierter Lösungen ermöglicht zudem oftmals, flexible Bezahlsysteme zu nutzen. So kann mit Dienstleistungsmodellen (z. B. Pay-per-Use) die Kostenplanung von zu implementierenden Projekten präzisiert werden (vgl. Abschnitt 5.2.2). Allerdings stellt dieses Vorgehen auch ein Risiko dar, da es zu einer Verlagerung von Fachwissen zum implementierenden Dienstleister kommen kann. Die erfolgreiche Einführung einer solchen KI-Maßnahme hängt, unabhängig von der verwendeten Technologie, maßgeblich von der Kompatibilität mit dem existierenden System ab.^{102,103,104}</p>
<p>Ausbau der IT-Infrastruktur</p>	<p>Entscheidend für die Unternehmen ist eine leistungsfähige IT-Infrastruktur. Das betrifft sowohl den Breitbandausbau als auch die mobilen Netze und (virtualisierten) Recheninfrastrukturen. KMU sind nicht nur in Ballungsräumen angesiedelt, sondern auch im ländlichen Raum. In jedem Fall sind sie auf eine gute Netzanbindung angewiesen. Das gilt sowohl für den Standort des Unternehmens als auch für die Erbringungsorte von Dienstleistungen.¹⁰⁵</p>

⁹⁹ Vgl. Uren, V. (2020).

¹⁰⁰ Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).

¹⁰¹ Vgl. Lundborg, M. und Märkel, C. (2019).

¹⁰² Vgl. Uren, V. (2020).

¹⁰³ Vgl. Wangermann, T. (2020).

¹⁰⁴ Vgl. Chen, H. (2019).

¹⁰⁵ Vgl. Wangermann, T. (2020).

Erfolgsfaktoren	Beschreibung
Demos oder Pilotprojekte zum Aufbau von Akzeptanz und Know-how	Oft konnten Unternehmen, die positive Erfahrungen mit der Implementierung erster simpler Demonstrationsprojekte gemacht haben, auch große Erfolge bei der weiteren Einführung von komplexen Lösungen bzw. bei deren Ausbau erzielen. Die Komplexität der Projekte steigt bei solch einem schrittweisen Vorgehen oftmals von Projekt zu Projekt immer weiter an, wobei einfache Demonstrationsanwendungen (sogenannte Quick-win-applications) den Anfang bilden und in komplexe KI-Lösungen münden. Diese entschleunigte Einführung von KI wirkt sich zudem positiv auf die Akzeptanz bei Mitarbeitenden aus. ^{106,107}
Nutzung von standardisierten Schnittstellen und Open-Source-Lösungen	Bei der Identifikation einer passenden KI-Lösung bietet sich für gewisse Anwendungen und Rahmenbedingungen die Wahl einer standardisierten Schnittstelle sowie einer erweiterbaren Architektur an. Dies ermöglicht die vereinfachte Integration von beispielsweise Maschinen- und Anlagensteuerungen sowie ERP-Systemen (vgl. Abschnitt 5.5.2) und eine Skalierung sowie Weiterentwicklung bereits implementierter KI. Open-Source-Lösungen profitieren zudem von der Schwarmintelligenz, da sie von freien Entwicklern in der ganzen Welt angepasst und optimiert werden können (vgl. hierzu auch Abschnitt 5.5.2). Dies kann einen signifikanten Wettbewerbsvorteil gegenüber anderen eher starren Lösungen bedeuten. ^{108,109, 110}
Unternehmensstrategisch	
Durchführung einer Machbarkeitsstudie	Vor Einführung einer KI-Lösung hilft die Durchführung eines Proof of Concept, Kosten und Aufwände zu ermitteln bzw. grob abzuschätzen. Dies soll die Allokation notwendiger Ressourcen vereinfachen. Kostenfallen werden so vermieden und die nachhaltige und durchgängige Umsetzung der Lösung ermöglicht. Während der Vorabstudie müssen sinnvolle Key Performance Indikatoren (KPI) identifiziert werden, um auf Basis der jeweiligen Ausprägung fundierte Aussagen hinsichtlich der zu erwartenden Amortisationszeit treffen zu können (vgl. Kapitel 5.2.2).
Entwicklung einer Strategie/Roadmap zur Einführung	Wesentlicher Erfolgsfaktor bei der Einführung von KI-Lösungen ist das Erarbeiten bzw. die Existenz einer klaren und langfristigen Strategie zur Implementierung, Nutzung und Weiterentwicklung der Technologie. Hierfür muss eine deutlich abgegrenzte Fragestellung existieren, um passende KI-Maßnahmen zu identifizieren. Zudem müssen Potenziale und Grenzen der zu implementierenden Maßnahme, aber auch von KI im Allgemeinen, im spezifischen Anwendungsfall identifiziert werden. Je nach Datenvolumen kann es Tage und sogar Wochen dauern, einen Algorithmus zu trainieren. Daher sollte anschließend ein detaillierter Fahrplan entwickelt werden, der die richtige KI-Architektur, eine Plattform für die Bereitstellung, eine Strategie für die Datenintegration und entsprechend geschulte Data-Scientists vorsieht. Sämtliche Schlüsselparteien wie Investoren, Behörden, Kunden, Abteilungen sollten dabei identifiziert werden. Es muss darauf geachtet werden, nicht mit wachsender Nachfrage an KI-Lösungen eine immer größere Datenmenge zu benötigen. ^{111, 112}

¹⁰⁶ Vgl. Uren, V. (2020).¹⁰⁷ Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).¹⁰⁸ Vgl. Streibich, K.-H. und Zeller, M. (2019).¹⁰⁹ Vgl. Chen, H. (2019).¹¹⁰ Vgl. Mathur, D.; Ahmad, Z. und Chamuah, A. (2020).¹¹¹ Vgl. Eidam, B. (2020).¹¹² Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).

Erfolgsfaktoren	Beschreibung
Aufbau neuer Kommunikationskanäle und Abbau von Hierarchien	Potenziell können der Abbau von Hierarchien und die Vereinfachung von Kommunikationswegen bei der Einführung von KI unterstützend wirken. So kann die Verringerung von Kommunikationsdistanzen – z. B. zwischen der Person an der Maschine, dem Programmierenden und der Person, die die KI bedient – dazu führen, dass sich vorhandenes Wissen besser innerhalb des Unternehmens verteilt. Die Entstehung von Wissensmonopolen wird gehemmt und durch aktive Kommunikation die Integration der neuen Technologie in den Arbeitsalltag gefördert. ¹¹³
Bereitstellung eines KI-Teams	Über ein eigens bereitgestelltes KI-Team können Wissen und Erfahrung aufgebaut werden, welches die erfolgreiche Umsetzung des KI-Projekts begünstigen. Die Teammitglieder dienen als zentrale Anlaufstelle bei Fragen und Problemen im Umgang mit KI. Gleichzeitig übernimmt die Gruppe im Idealfall aktiv die Kommunikation mit der Belegschaft, um für neue Technologien sowie Erfahrungen während der Implementierung zu sensibilisieren. Der Erfolg der Einführung einer KI-Maßnahme hängt oft stark mit den bei der Einführung beteiligten Personen zusammen. ^{114,115} Zudem ermöglicht der Aufbau von Wissen die nachhaltige Bearbeitung von KI-Projekten sowie die Identifikation weiterer Anwendungsfälle innerhalb des Unternehmens (vgl. Kapitel 5.5.2).
Angebot angemessener, umfassender KI-Trainings	Umfassende Schulungen der Belegschaft zu KI senken die Hemmschwelle der Anwendung. Weiterhin können etwaige Angstgefühle bezüglich Rationalisierung oder steigender Komplexität am Arbeitsplatz diskutiert und im Idealfall aufgehoben werden. Umgekehrt sind Einführungsprojekte oft stark beeinträchtigt, sofern keine angemessene Akzeptanz über die Potenziale künstlicher Intelligenz im Unternehmen geschaffen wird. ^{116,117} Solche Trainings und Schulungen können schnell, effektiv und niederschwellig als Online-Angebot durchgeführt werden (vgl. Kapitel 5.5.2).
Schrittweise Ausweitung der Entscheidungsbefugnisse	Insbesondere bei erstmaliger Einführung einer KI wird eine prüfinstanzlose Selbstständigkeit von KI oft als kritisch angesehen. Entsprechend wird die Akzeptanz innerhalb der Belegschaft signifikant erhöht, wenn KI zunächst als Entscheidungsunterstützung und eingeführte Qualitätsmetrik regelmäßig überwacht wird. Die Option, ein Veto einlegen zu können, wird vor allem während der Implementierungs-/Übergangsphase als probates Mittel gesehen, auch wenn dies in entsprechenden Fällen kontraproduktiv sein kann. ¹¹⁸
Schaffen eines flexiblen Arbeitsumfeldes mithilfe eingesetzter KI-Methoden	Als wirkungsvoller Enabler bei der erfolgreichen Einführung von KI-Maßnahmen werden die flexible Beteiligung und Einbindung von Mitarbeitenden gesehen. So wird diesen während der Implementierung die Möglichkeit gelassen, die jeweils eigene Rolle in diesem Prozess selbst festzulegen. Dies erhöht die Akzeptanz und die Identifizierung mit der neuen Technologie und unterstützt die Einbindung in den jeweiligen Arbeitsalltag. ¹¹⁹

¹¹³ Vgl. Rakova, B.; Yang, J.; Cramer, H. und Chowdhury, R. (2021).¹¹⁴ Vgl. Eidam, B. (2020).¹¹⁵ Vgl. Streibich, K.-H. und Zeller, M. (2019).¹¹⁶ Vgl. Eidam, B. (2020).¹¹⁷ Vgl. Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019).¹¹⁸ Vgl. Rakova, B.; Yang, J.; Cramer, H. und Chowdhury, R. (2021).¹¹⁹ Vgl. Rakova, B.; Yang, J.; Cramer, H. und Chowdhury, R. (2021).

Erfolgsfaktoren	Beschreibung
Vernetzung von KI-Anwenderschaft	<p>Einen entscheidenden Erfolgsfaktor kann die Nutzung der Plattform bzw. KI-Maßnahme/ Technologie von verschiedenen Teilnehmenden innerhalb der Branche bilden. Somit können Synergieeffekte erzielt werden und die Gemeinschaft profitiert von der Kumulierung von Wissen. Ein Erfahrungsaustausch auf Augenhöhe ermöglicht, dass nicht jedes Unternehmen die gleichen Hemmnisse und etwaigen negativen Erlebnisse durchlaufen muss.¹²⁰ Einrichtungen wie beispielsweise das Werner-von-Siemens Centre for Industry and Science bieten eine wirkungsvolle Plattform zur themenspezifischen und zielgerichteten Vernetzung. Der somit ermöglichte vorwettbewerbliche Wissensaustausch zwischen KMU fördert die Erschließung neuer Technologiefelder und Zukunftsthemen (vgl. Abschnitt 5.3.2).</p>
Begleitung der Umsetzung durch wirkungsvolles Changemanagement	<p>Oftmals besteht die Wahrnehmung, dass Berufsgruppen durch die Einführung von KI in ihrer eigenen Entscheidungsfreiheit durch KI-gestützte Empfehlungen untergraben werden. Die Folge kann mangelndes Vertrauen in die neue Technologie sein. Es kann der Eindruck entstehen, dass die Verantwortung und Erfahrung der einzelnen Personen an Bedeutung verlieren. Hierbei muss ein wirkungsvolles und strukturiertes Changemanagement ansetzen, um den Transformationsprozess einzuleiten und zu begleiten. Betroffene Personen müssen sensibilisiert und informiert werden. Perspektiven müssen aufgezeigt und frühzeitig kommuniziert werden (vgl. Abschnitt 5.8.2).</p>
Regulatorisch	
Regulierung/Vorgaben seitens des Gesetzgebers	<p>Oft sind Themen bezüglich Big Data und KI bereits durch den Gesetzgeber reguliert - dieser Umstand kann sowohl Hemmnis als auch Erfolgsfaktor für das Unternehmen sein.¹²¹</p>

¹²⁰ Vgl. Schössler, M. und Ebel, G. (2019).

¹²¹ Vgl. Chen, H. (2019).

7 HANDLUNGSFELDER FÜR KMU, POLITIK UND WISSENSCHAFT

Hauptgegenstand dieser Studie ist die Untersuchung des Einflusses von KI auf die betriebliche Ressourceneffizienz im verarbeitenden Gewerbe. Dabei liegt der Fokus vornehmlich auf KMU. Für sie stellen die Implementierung und Umsetzung von KI zunächst oft eine große Herausforderung dar. KMU, Politik und Wissenschaft bringen sowohl die ressourceneffiziente Nutzung von KI als auch Ressourceneffizienz durch KI mit viel Engagement voran - das Engagement sollte jedoch weiter gesteigert werden. Die Handlungsempfehlungen werden aus den Ergebnissen der systematischen Literaturrecherche, den darauf basierenden Expertenbefragungen und den Erkenntnissen der Praxisbeispiele abgeleitet. Abbildung 27 liefert eine Übersicht der identifizierten Handlungsfelder.

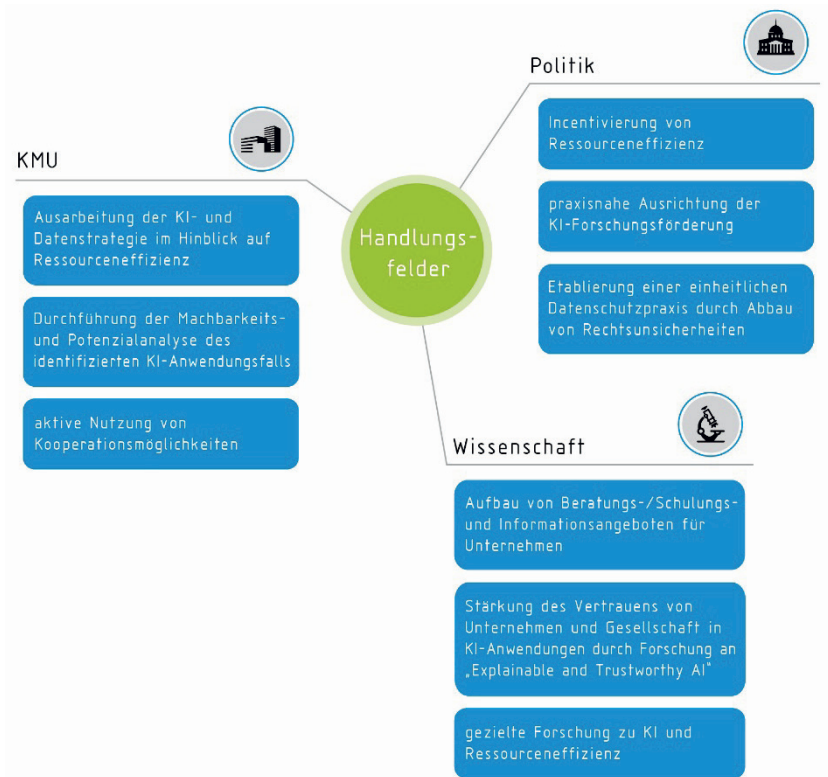


Abbildung 27: Übersicht identifizierter Handlungsfelder

7.1 Handlungsfelder für KMU

Die Handlungsfelder für KMU orientieren sich an dem bewährten Prozess zur erfolgreichen Umsetzung von KI-Projekten: Strategie, Machbarkeit, Implementierung und Skalierung.

7.1.1 Daten- und KI-Strategie

Speziell KMU sind in der Lage, schnell auf technologische Entwicklungen und Marktpotenziale zu reagieren und Forschungsergebnisse gezielt in neuen Produkten, Verfahren oder Dienstleistungen umzusetzen. Durch die Digitalisierung ändert sich zunehmend die klassische Wertschöpfungskette und neue Geschäftsmodelle entstehen. Die Bedeutung von Daten als Ressource nimmt dabei kontinuierlich zu. Wesentlicher Treiber und entschei-

dende Kernkomponente ist hierbei die Anwendung von KI. Diese bietet KMU die Möglichkeiten, Innovationsprozesse so auszurichten, dass neue Erkenntnisse und eine intelligente Wertschöpfung aus den vorhandenen Daten generiert werden können.

Handlungsempfehlung

Ausarbeitung der Daten- und KI-Strategie, auch in Hinblick auf Ressourceneffizienz

Aus der Umfrage geht deutlich hervor, dass in mehr als der Hälfte der befragten Unternehmen (56,4 %) KI noch nicht oder nur teilweise Bestandteil der Unternehmensstrategie ist. Um jedoch die beschriebenen Potenziale von KI auch in Hinblick auf die betriebliche Ressourceneffizienz heben zu können, wird insbesondere diesen Unternehmen empfohlen, ihre Unternehmensstrategie zu überdenken und anzupassen. Ohne eine klare strategische Ausrichtung des Unternehmens auf datengetriebenes Handeln wird die Umsetzung von KI-Initiativen deutlich erschwert.

Die Maßnahmen digitaler Transformation tragen zur Einsparung betrieblicher Ressourcen bei. Sowohl aus der Expertenbefragung (Abschnitt 3.3) als auch aus der Potenzialanalyse der Anwendungsszenarien (Kapitel 5) geht hervor, dass die Steigerung der Ressourceneffizienz bisher häufig nur ein positiver Nebeneffekt der Digitalisierungsmaßnahmen ist. Die Quantifizierung dieser Erfolge steht bisher für KMU oft nicht im Mittelpunkt. Weiterhin schlummert in den Unternehmen ungenutztes Potenzial, beispielsweise zur Identifizierung von Leckagen, zu Abweichungen von Normwerten, zur Verringerung der Fehlproduktion oder Überwachung des Ausschusses, welches mit der Einsparung von natürlichen Ressourcen einhergeht. KMU in Deutschland sind angehalten, sich mit der Nutzung und Einbettung von KI in Unternehmensprozesse zu beschäftigen, um keinen erheblichen Wettbewerbsnachteil zu erleiden.

Ein zwingender erster Schritt in diese Richtung ist die Ausarbeitung einer Daten- und KI-Strategie, welche sowohl Aspekte der Ressourceneffizienz als auch Aspekte der Ökonomie einbezieht. Die Steigerung der Ressourceneffizienz gewinnt zunehmend an Bedeutung. Dabei sind Energie- und

Materialverbräuche in Unternehmen oftmals mit geeigneten Maßnahmen leicht erfassbar. Ohne Etablierung einer Daten- und KI-Strategie rückt eine Dokumentation der Einsparungen in Form eines Datenmonitorings jedoch oft in den Hintergrund oder wird erst gar nicht vorgenommen. Die Ressourceneinsparungen werden in den meisten Fällen lediglich als positiver Nebeneffekt in den Betrieben wahrgenommen. Die dadurch potenziell gewonnenen und ausgewerteten Informationen bieten KMU jedoch vielversprechende Möglichkeiten zur Identifizierung und Realisierung weiterer Ressourceneffizienzpotenziale, die unbedingt genutzt werden sollten.

Anhaltspunkte zur Etablierung von KI in die Unternehmensstrategie und bestehende Geschäftsmodelle bietet die Studie „Künstliche Intelligenz: Potenzial und nachhaltige Veränderung der Wirtschaft in Deutschland“¹²². Diese enthält eine für KMU anwendbare Anleitung zur Ausarbeitung einer KI-Strategie in acht Schritten.

7.1.2 Machbarkeits- und Potenzialanalysen

Die in dieser Studie dargestellten KI-Anwendungsszenarien (Kapitel 5) können branchenübergreifend in vielen KMU des verarbeitenden Gewerbes zur Steigerung der Ressourceneffizienz genutzt werden. Welche Szenarien von KMU ausgewählt und in welchem Umfang sie umgesetzt werden, muss individuell an die Randbedingungen des Betriebes angepasst werden. Nach Bestimmung der innerbetrieblichen Möglichkeiten zur Anwendung von KI ist es essenziell, die Evaluierung der Ressourceneffizienz und des geschäftlichen Nutzens vorzunehmen.

¹²² Vgl. eco - Verband der Internetwirtschaft e. V und Arthur D. Little (2020).

Handlungsempfehlung

Durchführung von Machbarkeits- und Potenzialanalysen für identifizierte KI-Anwendungsszenarien

KMU sollten potenzielle KI-Anwendungsszenarien hinsichtlich der Machbarkeit und des Potenzials innerhalb der individuellen Rahmenbedingungen regelmäßig prüfen, da gerade im Bereich KI Entwicklungen rasant voranschreiten. Dafür kann auf vordefinierte Evaluationskriterien zurückgegriffen werden, welche unter anderem die Fairness, Kausalität, Transparenz und Sicherheit abdecken.

An dieser Stelle wird auf die Methodik zur Potenzialanalyse von Anwendungsszenarien in Kapitel 0 verwiesen, die als Leitfaden und Handlungsempfehlung für KMU dient. Dabei wird in Abschnitt 4.1 das notwendige Werkzeug dargestellt, um KI-Anwendungsszenarien zu analysieren und hinsichtlich ihres Einflusses auf die betriebliche Ressourceneffizienz zu bewerten. Darauf aufbauend wird in Abschnitt 4.2 ein Reifegradmodell vorgestellt, welches KMU die Einordnung der eigenen Position innerhalb von sechs Dimensionen ermöglicht.

7.1.3 Implementierung und Skalierung

Zeit- und Personalmangel sowie fehlendes Fachwissen zur Einführung von Maßnahmen der Digitalisierung im eigenen Betrieb stehen KMU oft im Wege, um sich einen Überblick über die Möglichkeiten der Digitalisierung in der Industrie zu verschaffen. Die Ergebnisse der Expertenbefragung bestätigten diese Erkenntnis. Jedoch geht aus den Umfrageergebnissen auch hervor, dass weitere Hemmnisse wie ein hoher Implementierungsaufwand oder die Identifikation geeigneter Technologien KMU oftmals noch von dem Einsatz einer KI abhalten.

Handlungsempfehlung

Implementierung und Skalierung durch aktive Nutzung von Kooperationsmöglichkeiten

Um dennoch identifizierte KI-Anwendungsszenarien implementieren und skalieren zu können, sollten KMU Kooperationsmöglichkeiten aktiv nutzen. Insbesondere, wenn die Erfahrung im eigenen Unternehmen noch nicht vorhanden ist, wird empfohlen, Kooperationspartner in Betracht zu ziehen: Netzwerke des KI-Ökosystems, Start-ups, Hochschulen oder Dienstleister. Bei der Einbeziehung externer Fachleute sollte auf einen angemessenen Wissenstransfer in das eigene Unternehmen geachtet werden. Auch eine unternehmensübergreifende Vernetzung, beispielsweise in Verbänden, kann für die Umsetzung von KI-Initiativen förderlich sein.

In der nationalen KI-Strategie setzt die Bundesregierung den Schwerpunkt auf Maßnahmen, durch die unter anderem KMU dazu befähigt werden, KI-Anwendungen zu nutzen, zu entwickeln und in ihre Geschäftsprozesse einzubeziehen¹²³. Auch die Datenstrategie des Bundes folgt diesem Ansatz¹²⁴. Dabei sollen insbesondere KMU dabei unterstützt werden, die Potenziale einer datenbasierten Wertschöpfung zu heben. Diese Möglichkeit sollten KMU als Startpunkt für die Implementierung und Skalierung der individuellen KI-Anwendungsszenarien nutzen, um aktiv an Initiativen wie „Mittelstand Digital“ des Bundesministeriums für Wirtschaft und Energie und Förderungsprogrammen wie „KMU-innovativ“ des Bundesministeriums für Bildung und Forschung teilzunehmen.

Eine aktive Nutzung von Initiativen und Förderprogrammen bietet KMU die Möglichkeit, Chancen und Herausforderungen der neuen Technologie zu erkennen, diese in konkrete Anwendungen umzusetzen und nicht zuletzt eine vereinfachte Bewilligung von Fördermitteln zu erlangen. Da vor allem KMU bei der Erschließung neuer Märkte besonders flexibel und

¹²³ Vgl. Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2018).

¹²⁴ Vgl. Presse- und Informationsamt der Bundesregierung (2021).

schnell sind, werden sie durch die Vernetzung mit passenden Kooperationspartnern dazu befähigt, erfolgreich am Markt mit neuen Produkten und Prozessen zu bestehen. Gerade in Bezug auf die Entwicklung geeigneter Algorithmen sowie deren Implementierung sind viele KMU noch auf externe Unterstützung angewiesen (siehe Kapitel 3.3). Entsprechend können diese Hürden durch die geeignete und aktive Nutzung von Kooperationsmöglichkeiten und die dadurch kurzfristige Bereitstellung personeller Ressourcen und Expertenwissen abgebaut werden.

7.2 Handlungsfelder für die Politik

Die Politik kann die Förderung künstlicher Intelligenz in vielen Bereichen weiter positiv beeinflussen. Dies betrifft vor allem die Förderung ressourceneffizienten Handelns, die praxisnahe Ausrichtung der KI-Forschungsförderung und Schaffung einer KI-freundlicheren Datenschutzpraxis.

7.2.1 Anreize und Motivation zur Ressourceneffizienz

Weltweit und auch in Deutschland ist der Rohmaterialverbrauch seit 1990 gestiegen, eine Trendwende ist bislang nicht zu erkennen. Mit der Rohmaterialgewinnung sind jedoch zwangsläufig Umweltauswirkungen wie beispielsweise Wasserverschmutzung oder Biodiversitätsverlust verbunden. Um die planetaren Grenzen nicht noch weiter zu überschreiten und unsere Lebensgrundlagen zu erhalten, muss dieser Trend umgekehrt und die Ressourceneffizienz erhöht werden: Ressourcen müssen also effektiver und effizienter genutzt werden.

Handlungsempfehlung

Anreize und Motivation zur Ressourceneffizienz

Bislang können viele Unternehmen ihren Ressourcenverbrauch und insbesondere die erzielten Einsparungen durch KI-Anwendungen nicht messen und angeben. Eine Einschätzung des Ressourcenverbrauchs vor und nach der Einführung von KI-Anwendungen ist jedoch Grundlage, um Verbesserungspotenziale aufdecken zu können. Daher müssen Anreize und Rahmenbedingungen geschaffen werden, um Ressourceneffizienz in Unternehmen zu quantifizieren und zu fördern. Dies kann durch die

Politik mithilfe entsprechender Förder- und Vernetzungsprogrammen erreicht werden. Zusätzlich kann das im Rahmen dieser Studie entwickelte und eingesetzte Kennzahlenmodell (siehe Abschnitt 4.1.4) Unternehmen bei der Quantifizierung ihrer Ressourceneffizienz unterstützen.

Während der vergangenen Jahre wurden diverse Beratungsangebote hinsichtlich Ressourceneffizienz, auch in Verbindung mit Digitalisierung, etabliert. Gleichwohl wird Ressourceneffizienz bei der Nutzung künstlicher Intelligenz in Unternehmen eher als ein Nebeneffekt angesehen und eine Quantifizierung der erreichten Verbesserungen ist nur in den seltensten Fällen möglich. Dieses wird in Kapitel 5 durch die dargestellten Praxisbeispiele deutlich. Hierdurch wird eine Verbreitung von Best-Practice-Beispielen erschwert, da der erreichte Mehrwert für andere Unternehmen nicht sichtbar wird. Daher wird empfohlen, den Fokus zusätzlich auf Förder- und Vernetzungsprogramme zu setzen, um Ressourceneffizienz bei der Implementierung künstlicher Intelligenz von Anfang an mit einzubeziehen. Umgekehrt kann die Verwendung von KI-Lösungen bei Ressourceneffizienzprogrammen explizit gefördert werden

Förder- und Vernetzungsprogramme können hierbei ergänzend wirken, indem zusätzliche Anreize geschaffen werden. Insbesondere Vernetzungsprogramme können durch den direkten Austausch zwischen den Unternehmen dazu führen, dass ähnliche Problemstellungen diskutiert und so erste Projekte im Bereich Ressourceneffizienz angestoßen werden. Hierbei profitieren die Unternehmen gegenseitig von ihren Erfahrungen.

Zudem kann das in dieser Studie entwickelte und im Rahmen der Potenzialanalyse ausgewählter Anwendungsszenarien in Kapitel 5 eingesetzte Kennzahlenmodell Unternehmen eine Orientierung für mögliche Verbesserungen hinsichtlich Ressourceneffizienz geben. Dieses soll den Einstieg in die Quantifizierung der Ressourceneffizienz erleichtern und in Zukunft eine Verbreitung von Best-Practice-Beispielen zur Steigerung der Ressourceneffizienz, insbesondere beim Einsatz von KI-Lösungen, ermöglichen.

7.2.2 KI-Forschungsförderung

Die Umfrageergebnisse aus Kapitel 3 zeigen deutlich, dass die Unternehmen bei der Einführung von KI Unterstützung durch Politik und Wissen-

schaft benötigen, um Barrieren, unter anderem in den Bereichen „hoher Implementierungsaufwand“, „fehlendes Know-how“ und „Identifikation geeigneter Technologien“, abzubauen. Es besteht Bedarf hinsichtlich einer praxisnahen Ausrichtung der KI-Forschungsförderung seitens der Politik, um zum einen die in Abschnitt 7.1.3 beschriebenen Ziele der Daten- und KI-Strategie des Bundes umsetzen und zum anderen KMU zielgerichtete und individuelle Hilfe zur Umsetzung des jeweiligen KI-Anwendungsszenarios bieten zu können.

Handlungsempfehlung

Praxisnahe Ausrichtung der KI-Forschungsförderung

Geeignetes Instrument hierfür sind Einrichtungen, die Möglichkeiten des Aufbaus von Testfeldern für KMU zur Erprobung von ressourceneffizienter KI und neuen Geschäftsmodellen in der Praxis bereitstellen. Diese werden flächendeckend mit genügend Kapazitäten in allen Regionen benötigt und müssen gefördert werden. Weiterhin muss für KMU ein vereinfachter Zugang zu KI-Technologien, Rechenkapazitäten und Cloud-Plattformen durch offene Standards gewährt werden. Dies ermöglicht die Nutzung des Ressourceneffizienzpotenzials von KI für zusätzliches Wirtschaftswachstum und Produktivitätszuwächse.

In der Studie „Ressourceneffizienz durch Industrie 4.0 - Potenziale für KMU des verarbeitenden Gewerbes“ (2017) wird empfohlen, dass von den Bundesministerien spezifische Fragestellungen für die Realisierung der Potenziale der digitalen Transformation zur Steigerung der Ressourceneffizienz integriert werden¹²⁵. Ferner wird nahegelegt, zukünftige Schwerpunktthemen der Forschungsförderung zur Entwicklung von Technologien und zur Generierung neuen Wissens zu entwickeln bzw. auszuarbeiten. Die praxisnahe Ausrichtung der KI-Forschungsförderung baut genau darauf auf und schlägt zum einen die Förderung von Einrichtungen wie dem in Abschnitt 5.3.2 vorgestellten Werner-von-Siemens Centre for Industry & Science e.V (WvSC) vor, in dem KMU die Möglichkeit haben, ihr identifi-

¹²⁵ Vgl. VDI Zentrum Ressourceneffizienz (2017).

ziertes KI-Anwendungsszenario zu erproben und zu testen. Zum anderen soll zur Komplementierung dieser Handlungsempfehlung ein vereinfachter Zugang zu KI-Technologien, Rechnerkapazitäten und Cloud-Plattformen durch offene Standards gewährt werden. Erst dadurch wird eine effiziente Anlaufstelle mit benötigten Ressourcen für eine praxisnahe KI-Forschung seitens der Befähiger und KMU durch die Politik bereitgestellt.

Sehr hohes Potenzial hierfür bietet die europäische Cloud- und Dateninfrastruktur GAIA-X¹²⁶, die laut dem Bundesministerium für Wirtschaft und Energie verschiedene Elemente über offene Schnittstellen und Standards miteinander vernetzen soll, um Daten zu verknüpfen und eine Innovationsplattform zu schaffen. Dabei steht das Projekt neuen Partnern, wie KMU oder Start-ups, offen. Es könnte durch den Einsatz sicherer, offener Technologien (Open Source, Open Hardware), ein gemeinsames Repository mit Software-Komponenten und auf gemeinsamen EU-Werten beruhende Standards, die Hemmschwellen für eine Umsetzung von KI-Anwendungsfällen in KMU zukünftig stark reduzieren. Aufbauend auf dem am 21. Januar 2021 vom Deutschen Forschungszentrum für Künstliche Intelligenz gestarteten Projekt „Agri-Gaia“¹²⁷, sollte eine offene, dezentrale Infrastruktur für die Entwicklung und den Austausch von KI-Algorithmen zwischen produzierenden Unternehmen für weitere KI-Forschung gefördert werden. So können branchenspezifisch adaptierte KI-Bausteine als leicht verwendbare Module bereitgestellt werden. Zudem bietet sich die Möglichkeit, durch dieses neugeschaffene Ökosystem Anwender/innen mit Entwickler/innen von KI-Algorithmen zusammenzubringen.

7.2.3 Datenschutz, Datennutzung und Datenzugang

Auch wenn Sicherheitsbedenken und regulatorische Bedenken bei den Umfrageergebnissen (siehe Kapitel 6.1) eine eher untergeordnete Rolle spielen, bleiben sie unumstritten relevant. Die Komplexität des deutschen Systems wurde durch die Etablierung der Datenschutz-Grundverordnung und des Europäischen Datenschutzausschusses (EDSA) deutlich erhöht.

¹²⁶ Vgl. Bundesministerium für Wirtschaft und Energie (2021b).

¹²⁷ Vgl. Bundesministerium für Wirtschaft und Energie (2021a).

Fernerhin erschwert die bislang uneinheitliche Datenschutzpraxis eine standortübergreifende Verbundforschung zwischen den Ländern. Die Uneinheitlichkeit und Rechtsunsicherheit sind potenzielle Bedrohungen für das Wachstum und die Entwicklung der deutschen Wirtschaft.

Handlungsempfehlung

Etablierung einer einheitlichen Datenschutzpraxis durch Abbau von Rechtsunsicherheiten

Demnach besteht seitens der Politik Handlungsbedarf in Hinblick auf die Entwicklung datenethischer Standards sowie eine KI-freundliche Datenstrategie. Dadurch soll aus dem Dreiklang Datenschutz, Datennutzung und Datenzugang eine für KMU transparente Basis geschaffen werden. Dies benötigt Bund-Länder-Arbeitsgruppen mit dem Ziel, eine bundeseinheitliche forschungsfreundliche Datenschutzpraxis zu etablieren, um unter anderem durch konsistente und einheitliche Grundsätze Rechtsunsicherheiten abzuschaffen.

Nicht alles, was technisch möglich ist, ist bei der Nutzung von Daten auch ethisch vertretbar und wünschenswert für die Politik. In der Datenstrategie des Bundes¹²⁸ wird festgehalten, dass Daten nur dann bereitwillig von den Akteur/innen eines Daten-Ökosystems geteilt und genutzt werden, wenn die Dateninfrastruktur vertrauenswürdig und die Sicherheit der Daten gewährleistet ist. Datenschutz und IT-Sicherheit müssen demnach von vornherein in Produkten und Prozessen mitgedacht werden. Des Weiteren wird auf divergierende datenschutzrechtliche Regelungen auf Landesebene hingewiesen. Die Herausforderung für Deutschland liegt hierbei in der Schaffung eines einheitlichen Ansatzes aller Landesdatenschutzbehörden zur Erarbeitung von Leitlinien. Bisher sind in den einzelnen Bundesländern die Datenschutzbehörden in ihrer Rechtsauslegung grundsätzlich frei. Für die erfolgreiche Entwicklung und Anwendung von KI-Anwendungsszenarien in KMU bedarf es jedoch verlässlicher und transparenter rechtlicher Rahmenbedingungen auf EU-Ebene. Wie in dem „VDI-

¹²⁸ Vgl. Presse- und Informationsamt der Bundesregierung (2021).

Statusreport – Maschinelles Lernen“¹²⁹ festgehalten, werden die Verfügbarkeit industrieller Daten und die Freiheit ihrer Nutzung in naher Zukunft eine wesentliche Grundlage der Souveränität eines Wirtschaftsraums bilden – und hierfür werden umso mehr klare Regelungen benötigt. Dies betrifft Fragestellungen bezüglich der Eigentums- oder Nutzungsrechte an verwendeten Daten, der Grenzen individueller Rechte an Daten und der Rechte an den Ergebnissen von Lernverfahren für KI¹³⁰.

Die KI-Strategie des Bundes sieht eine Prüfung bestehender Rechtsrahmen mit Blick auf neue KI-Technologien vor¹³¹. Dabei sollen Algorithmen- und KI-basierte Entscheidungen, Dienstleistungen und Produkte auf Lücken überprüft und gegebenenfalls angepasst werden, um diese in Hinblick auf mögliche unzulässige Diskriminierungen und Benachteiligungen überprüfbar zu machen. Ziel ist unter anderem die Schaffung eines rechtssicheren Ordnungsrahmens für KI-Akteure in Unternehmen, Start-ups, Wissenschaft und Forschung, der Bevölkerung und öffentlichen Verwaltung¹³².

7.3 Handlungsempfehlungen für die Wissenschaft

Die Wissenschaft als Innovationsträger und -förderer kann die Einbindung von KI-Lösungen in Unternehmen gezielt unterstützen. Insbesondere wird ein Transfer von der Wissenschaft in die Praxis benötigt, um vorherrschende Einstiegshürden abbauen zu können. Dieses kann durch Beratungs-, Schulungs- und Informationsangebote im Rahmen anwendungsnaher Forschung erreicht werden. Zudem kann das Vertrauen von Unternehmen und Gesellschaft in KI-Anwendungen durch Forschung an „Explainable and Trustworthy AI“ gestärkt werden. Forschungsprogramme mit der Fokussierung auf Ressourceneffizienzpotenziale bei der Einbindung von KI-Lösungen ebnen den Weg nach Ausrichtung der vorliegenden Studie.

¹²⁹ Vgl. VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik (2019).

¹³⁰ Vgl. VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik (2020).

¹³¹ Vgl. Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2018).

¹³² Vgl. Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2020).

7.3.1 Beratungs-, Schulungs- und Informationsangebote für Unternehmen

Laut den Ergebnissen der durchgeführten Umfrage sind die mangelnde Kenntnis über KI sowie deren Potenziale ein relevantes Hemmnis für deren Einführung. Neben allgemeinen Fragestellungen hinsichtlich Begrifflichkeiten und Definitionen herrscht insbesondere über geeignete Technologien Unklarheit. Zudem existieren diverse Bedenken bezüglich der Einbindung innovativer Technologien in etablierte Prozesse (siehe Kapitel 6.1). Dies betrifft verschiedene Interessenvertretende im gesamten Unternehmen.

Handlungsempfehlung

Aufbau von Beratungs-, Schulungs- und Informationsangeboten für Unternehmen

Wissenschaftliche Einrichtungen können als unabhängige Instanzen unvoreingenommen und objektiv über die Ressourceneffizienzpotenziale von KI im betrieblichen Umfeld aufklären. Indem der recht vage und umfassende Begriff KI anhand konkreter Anwendungsszenarien und Methoden erklärt wird, kann der konkrete Nutzen vor allem im Bereich Ressourceneffizienz für Unternehmen aufgezeigt werden. Hierfür müssen niederschwellige Informationsangebote konzipiert werden. Bei Anklang in der Industrie sollten auf dieser Basis tiefergreifende Schulungen erarbeitet und angeboten werden. Zweck ist die zielgerichtete Verbreitung von ressourcenschonender KI insbesondere in KMU durch Sensibilisierung der Mitarbeitenden.

Das grundlegende Informationsangebot sollte als niederschwelliger Türöffner in die KI-Thematik im betrieblichen Umfeld dienen. Neben Begrifflichkeiten und grundlegenden Definitionen werden verschiedene Methoden der KI und mögliche Anwendungsszenarien diskutiert.

Das zu entwickelnde Schulungsangebot erfüllt den Zweck, betroffene Parteien objektiv über die Chancen und Risiken der Einführung von KI-Methoden aufzuklären. Neben ökonomischen, ökologischen und sozialen Aspekten werden dabei auch technologische fokussiert. Im Idealfall verlassen Teilnehmende das Angebot mit einem Überblick über unbegründete

und begründete Bedenken sowie Potenziale in ihrem Unternehmen. Auch sollten die Grundlagen aus dem Basis-Informationsangebot aufgegriffen und Wissen im Bereich von KI-Methoden sowie deren Vor- und Nachteile vertieft werden. Teilnehmende sollen entsprechend befähigt werden, im Anschluss an die Schulung eigenständig eine erste Einschätzung zu treffen, inwiefern KI für das eigene Unternehmen von Interesse sein kann.

Die Informations- und Schulungsangebote sollten dabei einen klaren Fokus auf einen zielgerichteten Einsatz von KI legen. Die Einbindung entsprechender Systeme ist bis dato nur in einigen Anwendungen sinnvoll. Oftmals eignen sich auch spezielle Branchen bzw. Produktionsprozesse besser als andere. Neben diesen allgemeinen Informationen auf Basis von Erfahrungswerten muss in Unternehmen die Notwendigkeit einer individuellen Prüfung kommuniziert werden. Aufwand und Nutzen sollten genau untersucht werden und spezifische Bewertungen sollten ergeben, inwiefern eine zielgerichtete einer breitangelegten Anwendung vorzuziehen ist. Derartige Analysen sind als Beratungsleistungen seitens wissenschaftlicher Einrichtungen denkbar. Hierzu müssten Kriterien- und Bewertungsmodelle erarbeitet und validiert werden. Den Unternehmen wird somit eine Entscheidungsunterstützung hinsichtlich der Einbindung von KI-Methoden im eigenen Produktionsumfeld an die Hand gegeben. Bei Bedarf ist eine Begleitung bei der Umsetzung durch qualifizierte Stellen denkbar.

7.3.2 Vertrauen von Unternehmen und Gesellschaft in KI-Anwendungen

Damit Unternehmen mithilfe von KI tatsächlich Wettbewerbsvorteile erlangen können, müssen die eingesetzten Systeme verlässlich und vertrauenswürdig sein. Sowohl Kunden als auch die Unternehmen selbst müssen den eingesetzten Systemen vertrauen. In der Umfrage sind Kundenvertrauen und Sicherheitsbedenken für Unternehmen zwar nur untergeordnete Hemmnisse (siehe Abschnitt 3.3), obgleich die Nachvollziehbarkeit von KI in diesem Kontext trotzdem eine Grundvoraussetzung für ihre breite Einsatzfähigkeit darstellt.

Handlungsempfehlung

Stärkung des Vertrauens von Unternehmen und Gesellschaft in KI-Anwendungen durch Forschung an „Explainable and Trustworthy AI“

Durch Forschung an „Explainable and Trustworthy AI“ kann das benötigte Vertrauen in KI gestärkt und die Ergebnisse, die eine KI liefert, können nachvollziehbar und erklärbar werden. Forschungsgebiete in diesem Bereich sind vor allem Autonomie und Kontrolle, Transparenz, Verlässlichkeit, Sicherheit und Datenschutz der KI.

KI besitzt ein disruptives Potenzial – es ist also bisher noch nicht absehbar, welche Erkenntnisgewinne und zukünftigen Anwendungen mit KI möglich sein werden. Zudem können Business-Modelle und ganze Branchen durch diese Technologie tiefgreifend verändert werden. Genau aus diesem Grund ist die Forschung im Bereich „Explainable and Trustworthy AI“ besonders wichtig. Das Themenfeld beschäftigt sich damit, nachvollziehbare sowie rechtskonforme ethische und robuste KI zu entwickeln. Ziel ist es, aufzuzeigen, auf welche Weise die eingesetzte KI zu ihren Ergebnissen kommt und die Sicherheit beim Einsatz von KI gewährleistet. Zu beachten sind insbesondere komplexe KI-Anwendungsszenarien, die z. B. die Verwendung neuronaler Netze beinhalten und somit eine erhebliche Erschwerung der Erklärbarkeit der Ergebnisse mit sich bringen. Durch die Forschung im Bereich „Explainable and Trustworthy AI“ können zudem Risiken bei der Sicherheit, Verantwortlichkeit, Haftung und Ethik, die in der Entwicklung

bzw. während der Nutzung von KI auftreten können, frühzeitig identifiziert sowie minimiert oder gar beseitigt werden. Dies ist die Voraussetzung für die langfristige Sicherung der Wettbewerbsfähigkeit von Unternehmen.

Die Forschung sollte einerseits „Explainable and Trustworthy AI“ selbst entwickeln, um KI für Unternehmen breit anwendbar zu machen. Andererseits kann sie als unabhängige Instanz dabei unterstützen, Prüfverfahren für KI zu entwickeln, um somit KI auf die oben genannten Kriterien zu testen und in Zukunft eine Zertifizierung zu ermöglichen. Diese entwickelten Prüfverfahren können damit auch die Grundlage für Standards und Normen bilden. Durch diese beiden Schritte kann das Vertrauen in KI maßgeblich gestärkt und eine breite sowie zuverlässige Anwendbarkeit für Unternehmen sichergestellt werden.

7.3.3 Forschung zu KI und Ressourceneffizienz

Durch die in Kapitel 6.1 beschriebene Literaturrecherche wurde einerseits die Ungewissheit hinsichtlich der ökologischen Auswirkungen von KI als relevantes Hemmnis identifiziert. Zudem wird angenommen, dass bei der Entwicklung von KI-Methoden signifikante negative Umweltwirkungen generiert werden. Andererseits können KI-Lösungen den effizienten Einsatz natürlicher Ressourcen unterstützen. Bezüglich möglicher Trade-offs zwischen ökologischen und ökonomischen Zielen fehlen standardisierte und nachvollziehbare Bewertungsansätze und -maßstäbe.

Handlungsempfehlung

Gezielte Forschung zu KI und Ressourceneffizienz

Gezielte Forschungsanstrengungen zu KI und Ressourceneffizienz sollen Transparenz bezogen auf die ökologischen und ökonomischen Auswirkungen einer entsprechenden Implementierung schaffen. Diese Analysen müssen einen ganzheitlichen Ansatz verfolgen und sämtliche Phasen des Lebenswegs von KI-Lösungen integriert betrachten. Anwenden wird somit ein niederschwelliges Informationsangebot hinsichtlich des Nutzens von KI-Methoden im Produktionsumfeld zur Verfügung gestellt. Auf Grundlage dieses Basiszustandes können Optimierungsmaßnahmen beforscht werden.

Die vorliegende Studie betrachtet Auswirkungen von KI-Methoden auf die Ressourceneffizienz im Produktionsumfeld. Dabei werden relevante Potenziale identifiziert und Best Practices diskutiert. Nichtsdestotrotz wird ersichtlich, dass die derzeitige Forschungslandschaft keinen expliziten Fokus auf zu realisierende Ressourceneffizienzpotenziale durch KI legt. Durch ein gesteigertes Bewusstsein über die Vorzüge einer zukunftsfähigen und nachhaltigen Produktion nimmt dieser Aspekt für die potenzielle Anwendung jedoch eine zentrale Rolle ein. Der wissenschaftliche Diskurs sollte daher auf vorhandenen Erkenntnissen aufbauen und vertiefendes Wissen in diesem Bereich generieren. Mehrwerte im Kontext der Ressourceneffizienz sollten dabei gezielt herausgearbeitet werden. Weitere Anwendungsszenarien müssen geprüft und bestehende um den Nutzen hinsichtlich Ressourceneinsparungen erweitert werden. Insbesondere ganzheitliche Analysen sind hierbei von großer Bedeutung. Um langfristige Nachhaltigkeit zu erzielen, sind nicht nur die potenziell positiven Auswirkungen der Einbindung von KI-Methoden zu untersuchen, sondern es sollten in entsprechenden Betrachtungen sämtliche Lebensphasen der notwendigen Software und Hardware einbezogen werden. Dabei sind die Ressourceneffizienzpotenziale sowohl der KI-Lösungen als auch die hierzu erforderliche Hardware und Elektronik zu betrachten. Die jeweiligen Aufwände und Nutzen für Ressourceneffizienz müssen über den gesamten Lebensweg hinweg verrechnet werden. Es resultiert ein Überblick über die Netto-Umweltwirkungen und Ressourcenverbräuche. Dieser ermöglicht zielgerichtete Entscheidungen bezüglich der Einbindung von KI-Lösungen mit Blick auf eine systemgrenzen-übergreifende Verwirklichung der angestrebten nachhaltigen Produktion. Die Darstellung dieses Ausgangszustandes dient zudem der Identifikation relevanter Stellhebel und der Fokussierung von Forschungsanstrengungen auf eine ganzheitliche Optimierung. Erhöhen konkrete Prozesse die Inanspruchnahme von Natur und Ressourcen im besonderen Maße, sollten vor allem in diesen Bereichen mögliche Verbesserungen erforscht werden. Die Rolle der Forschung liegt entsprechend neben der grundlegenden Bilanzierung ebenfalls in der systematischen Optimierung durch Reduktion der Umweltwirkungen in relevanten Bereichen/Lebensphasen der für KI notwendigen Komponenten.

8 ZUSAMMENFASSUNG UND FAZIT

Ressourceneffizienz ist ein zentrales Thema heute und zukünftig, welchem sich insbesondere der Wirtschaftsstandort Deutschland in Anbetracht knapper werdender Rohstoffe mit innovativen Ansätzen widmen muss. Diese Studie zeigt auf, dass schwache künstliche Intelligenz großes Potenzial hat, zu ressourceneffizientem betrieblichen Handeln beizutragen. Die Untersuchung verdeutlicht jedoch ebenso, dass zunächst Hemmnisse beseitigt und bestehende Erfolgsfaktoren verstärkt werden müssen, um diese Potenziale vollständig abzurufen. Die Potenziale liegen einerseits in den Voraussetzungen und Fähigkeiten der Unternehmen, schwache künstliche Intelligenz in der betrieblichen Praxis flächendeckend einzusetzen. Andererseits muss die Wissenschaft den Transformationsprozess hin zu stärkerer Einbindung von KI im betrieblichen Umfeld begleiten und unterstützen. Für kleine und mittlere Unternehmen trifft dies in besonderem Maße zu. Daher fokussiert die vorliegende Studie eben diese.

Sie identifiziert weiterhin die verfügbaren Technologien und Methoden der schwachen künstlichen Intelligenz. Eine umfassende Literaturrecherche verknüpft diese mit der Wertschöpfungskette des verarbeitenden Gewerbes, um typische Anwendungsszenarien zu ermitteln. Diese werden hinsichtlich ihres Einflusses auf die betriebliche Ressourceneffizienz überprüft. Hier zeigt sich, dass viele Anwendungen schwacher künstlicher Intelligenz noch nicht mit Blick auf eine Steigerung der Ressourceneffizienz implementiert werden. Die Einsparung natürlicher Ressourcen ist oftmals ein positiver sekundärer Effekt bei der Einführung künstlicher Intelligenz, nicht jedoch ihre Hauptmotivation.

Eine Expertenbefragung mit 71 Teilnehmenden prüft diese und weitere Hypothesen auf ihre Richtigkeit im operativen Umfeld. Bezüglich der Motivation des Einsatzes schwacher künstlicher Intelligenz zeigt sich ein differenziertes und vielversprechendes Bild: Zwar lagen anvisierte Zielstellungen bereits implementierter KI-Anwendungen zumeist auf der Einsparung von Kosten (25,7%) und Zeit (20%) sowie der Verbesserung von Qualität (22,9%) und der Schaffung von Wettbewerbsvorteilen (18,6%), allerdings werden Ressourceneinsparungen zukünftig bei der Einführung von KI-Anwendungen (Energie: Steigerung von 5,7% auf 12,6%, Material: Steige-

zung von 4,3% auf 8,9% und CO₂-Emissionen: Steigerung von 1,4% auf 5,2% stärker in den Fokus rücken (vgl. Abbildung 6).

Gleichzeitig offenbart sich eine Herausforderung vieler KI-Anwendungen. Die durchgeführte Befragung ergibt, dass die Erwartungen an die Ressourceneinsparpotenziale höher sind als die tatsächlich realisierten Einsparungen, was jedoch auch darauf zurückgeführt werden kann, dass viele Ressourcenverbräuche oft gar nicht gemessen werden und es sich daher nur um Schätzwerte handelt.

Weiteres zentrales Ergebnis der Erhebung ist, dass 60% der befragten Unternehmen auf externe Unterstützung bei der Implementierung von KI-Anwendungen zurückgreifen. Fehlendes Fachwissen (54,2%) und Mangel an Personal (54,2%) und Zeit (41,7%) werden als Hauptgründe gegen eine Eigenentwicklung angeführt.

Um die Durchführbarkeit der Potenzialanalyse aufzuzeigen und die Verbreitung von Best-Practices voranzutreiben, werden acht Anwendungsszenarien schwacher künstlicher Intelligenz ausgewählt: Vorausschauende Wartung, Optimierung der Prozesskette, optische Fehlererkennung, Fehlervorhersage, Planung der Prozesskette, Produktoptimierung, autonome Transportsysteme und Sustainability Analytics (Kapitel 5). Ihnen werden sowohl in relevanter Fachliteratur (vgl. Abschnitt 2.3) als auch während der Expertenbefragung (Kapitel 3) positive Auswirkungen auf die betriebliche Ressourceneffizienz zugeschrieben. Für jedes Anwendungsszenario wird an mindestens einem Praxisbeispiel aufgezeigt, wie und mit welchen Ergebnissen die Implementierung gelingen kann. Die Anwendungsszenarien und Praxisbeispiele werden anhand primär qualitativer Ressourceneffizienzbetrachtungen untersucht und vorgestellt.

Um die Durchführbarkeit der Potenzialanalyse aufzuzeigen und die Verbreitung von Best-Practices voranzutreiben, werden acht Anwendungsszenarien schwacher künstlicher Intelligenz ausgewählt (Kapitel 5), denen sowohl in relevanter Fachliteratur (vgl. Abschnitt 2.3) als auch während der Expertenbefragung (Kapitel 3) positive Auswirkungen auf die betriebliche Ressourceneffizienz zugeschrieben wurde. Für jedes Anwendungssze-

nario wird an mindestens einem Praxisbeispiel aufgezeigt, wie und mit welchen Ergebnissen die Implementierung gelingen kann.

Aus diesen Untersuchungen und Ergebnissen werden wesentliche unternehmensstrategische, technologische, ökonomische, ökologische, soziale und regulatorische Erfolgsfaktoren sowie Hemmnisse abgeleitet. Bei den Hemmnissen konnten Unterschiede zwischen Unternehmen herausgearbeitet werden, die bereits künstliche Intelligenz einsetzen, und solchen, die es noch nicht tun.

Unternehmen, die bereits Erfahrung mit künstlicher Intelligenz gemacht haben, sehen in der fehlenden Datengrundlage, dem hohen Implementierungsaufwand und fehlendem Fachwissen die größten Hemmnisse für weitere Implementierungen. Für Unternehmen, die noch keine Erfahrungen mit künstlicher Intelligenz gesammelt haben, sind z.T. signifikante Unterschiede in der Gewichtung der jeweiligen Hemmnisse zu erkennen. Fehlendes Fachwissen, hoher Implementierungsaufwand und die Identifikation geeigneter Technologien bilden hier die höchsten Eintrittsbarrieren.

Neben Hemmnissen wurden durch die vorliegende Studie aber auch Erfolgsfaktoren identifiziert, welche die Implementierung von Anwendungsszenarien künstlicher Intelligenz begünstigen. Bereits durch geringe Investitionen in die Ausbildung von Mitarbeitenden (z.B. kostenlose Schulungen auf Videoplattformen oder Onlinekurse) können die Umsetzung und Bedienung der KI-Lösung vereinfacht und unterstützt werden. Die Vernetzung mit den im Abschnitt 1.1.2 beschriebenen KI-Ökosystemen ist ein weiterer relevanter Erfolgsfaktor. Damit interessierte Betriebe an den angebotenen Leistungen teilhaben und davon profitieren können, bedarf es keines großen Aufwands. Andere Erfolgsfaktoren erfordern oftmals weitaus umfangreichere zeitliche und finanzielle Vorleistungen. So können die Ausgestaltung einer KI-Strategie, die Schaffung der notwendigen Akzeptanz im Unternehmen und der Ausbau der IT-Infrastruktur deutlich mehr Kräfte und Mittel binden.

Die Erkenntnisse der Studie münden in Handlungsempfehlungen für KMU, Politik und Wissenschaft. Demnach müssen KMU zügig die Voraussetzungen für die Einführung künstlicher Intelligenz schaffen und sollten mit

einer zielgerichteten Daten- und KI-Strategie beginnen. Außerdem kann die Durchführung von Machbarkeitsstudien für potenzielle KI-Anwendungen das Risiko während der Implementierung mindern. Hierbei kann und sollte auf dafür vorgesehene Testfelder (z.B. Werner-von-Siemens Centre for Industry and Science) zurückgegriffen werden. Bei der Implementierung und Skalierung sollten KMU Kooperationsmöglichkeiten und Angebote aus dem KI-Ökosystem nutzen. Die Politik kann weitere Anreize für ressourceneffizientes Handeln schaffen und mit einer praxisnahen Ausrichtung der KI-Forschungsförderung Eintrittsbarrieren abbauen. Außerdem sollten Rechtsunsicherheiten in der Datenschutzpraxis weiter verringert werden. Die Wissenschaft kann durch den Auf- und Ausbau von Beratungs- und Schulungsangeboten sowie durch Forschung im Bereich „Trustworthy and Explainable AI“ die Akzeptanz und das Vertrauen in künstliche Intelligenz weiter stärken. Zudem bedingt die bis dato mangelnde Verknüpfung der Themenfelder künstliche Intelligenz und Ressourceneffizienz die Notwendigkeit gezielter Forschungsleistungen.

Der deutsche Mittelstand beobachtet die aktuellen Entwicklungen rund um künstliche Intelligenz mit Spannung. Laut einer aktuellen Studie von Deloitte Private werden neben bekannten Erwartungen wie der Automatisierung und Beschleunigung von Prozessen und der Realisierung von Einsparpotenzialen mittlerweile auch neue Geschäftsmodelle als Chance der Umsetzung von künstlicher Intelligenz wahrgenommen¹³³. Damit diese und weitere Erwartungen ebenso in Hinblick auf die Erhöhung der betrieblichen Ressourceneffizienz realisiert werden können, ist konsequentes Handeln von allen Akteuren gefragt. Diese Studie bietet Hilfestellungen und Beispiele für diejenigen, die bereit sind, diesen Weg einzuschlagen.

¹³³ Vgl. Deloitte Private (2021).

LITERATURVERZEICHNIS

Abdelkafi, N.; Döbel, I., Drzewiecki, J.; Meironke, A.; Niekler, A. und Ries, S. (2019): Künstliche Intelligenz (KI) im Unternehmenskontext – Literaturanalyse und Thesenpapier. Fraunhofer-Zentrum für Internationales Management und Wissensökonomie IMW, Leipzig [abgerufen am: 16.04.2021], verfügbar unter: <http://publica.fraunhofer.de/starweb/servlet.starweb?path=epub.web&search=N-555812>

AI.HAMBURG (2021): Internationale AI Expertise für die Wirtschaft [online]. AI for Hamburg GmbH [abgerufen am: 05.05.2021], verfügbar unter: <https://ai.hamburg/>

Alsheiabni, S.; Cheung, Y. und Messom, C. (2019): Towards An Artificial Intelligence Maturity Model: From Science Fiction To Business Facts. In: PACIS 2019 Proceedings, S. 46 [abgerufen am: 12.04.2021], verfügbar unter: <https://aisel.aisnet.org/pacis2019/46>

atlan-tec Systems GmbH (2021): Mithilfe von Smart Data nachhaltige Wertschöpfung schaffen [online] [abgerufen am: 03.05.2021], verfügbar unter: <https://atlan-tec.com/>

Bhatia, P.; Ranganathan, J.; Gage, P.; Corbier, L.; Schmitz, S. und Oren, K. (2004): The greenhouse gas protocol – A corporate accounting and reporting standard, Washington, ISBN 1-56973-568-9.

Blechwarenfabrik Limburg GmbH (2021): Aus Tradition innovativ! Blechwarenfabrik Limburg GmbH [online] [abgerufen am: 06.05.2021], verfügbar unter: <https://www.blechwaren-limburg.de/>

BMU (2016): Klimaschutzplan 2050 – Klimaschutzpolitische Grundsätze und Ziele der Bundesregierung. 2. Auflage. Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit (BMU), Referat Öffentlichkeitsarbeit, Online-Kommunikation [abgerufen am: 15.04.2021], verfügbar unter: <https://www.bmu.de/download/klimaschutzplan-2050/>

BMU (2020): Deutsches Ressourceneffizienzprogramm (ProgRes) [online]. Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit, 17.06.2020 [abgerufen am: 25.03.2021], verfügbar unter: <https://www.bmu.de/themen/wirtschaft-produkte-ressourcen-tourismus/ressourceneffizienz/deutsches-ressourceneffizienzprogramm/>

Bostrom, N. und Yudkowsky, E. (2014): The ethics of artificial intelligence. In: Frankish, K. und Ramsey, W.M., Hg. The Cambridge Handbook of Artificial Intelligence, Cambridge University Press, Cambridge, S. 316 - 334. ISBN 9781139046855.

Brynjolfsson, E.; Rock, D. und Syverson, C. (2017): Artificial Intelligence and the Modern Productivity Paradox: A Clash of Expectations and Statistics. National Bureau of Economic Research, Cambridge, MA.

Bundesamt für Wirtschaft und Ausfuhrkontrolle (2020): Merkblatt für Energieaudits nach den gesetzlichen Bestimmungen der §§ 8ff. EDL-G. Bundesamt für Wirtschaft und Ausfuhrkontrolle (Bafa), Leitungsstab Presse- und Sonderaufgaben, Eschborn [abgerufen am: 16.04.2021], verfügbar unter: https://www.bafa.de/SharedDocs/Downloads/DE/Energie/ea_merkblatt.html

Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2018): Strategie Künstliche Intelligenz der Bundesregierung. Die Bundesregierung [abgerufen am: 16.04.2021], verfügbar unter: <https://www.bmwi.de/Redaktion/DE/Publikationen/Technologie/strategie-kuenstliche-intelligenz-der-bundesregierung.html>

Bundesministerien für Bildung und Forschung, Wirtschaft und Energie, Arbeit und Soziales (2020): Strategie Künstliche Intelligenz der Bundesregierung - Fortschreibung 2020. Die Bundesregierung [abgerufen am: 16.04.2021], verfügbar unter: <https://www.bmwi.de/Redaktion/DE/Publikationen/Technologie/strategie-kuenstliche-intelligenz-fortschreibung-2020.html>

Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit (2021): Unsere Förderinitiative "KI-Leuchttürme" [online] - 40 Millionen Euro für Umweltschutz mit KI [abgerufen am: 20.05.2021], verfügbar unter: <https://www.bmu.de/themen/europa-internationales-nachhaltigkeit->

digitalisierung/digitalisierung-und-umwelt/unsere-foerderinitiative-ki-leuchttuerme/

Bundesministerium für Wirtschaft und Energie (2021a): Agri-Gaia [online]. Bundesministerium für Wirtschaft und Energie [abgerufen am: 06.05.2021], verfügbar unter: <https://www.bmwi.de/Redaktion/DE/Artikel/Digitale-Welt/GAIA-X-Use-Cases/agri-gaia.html>

Bundesministerium für Wirtschaft und Energie (2021b): GAIA-X [online] – Eine vernetzte Datenstruktur für ein europäisches digitales Ökosystem. Bundesministerium für Wirtschaft und Energie [abgerufen am: 06.05.2021], verfügbar unter: <https://www.bmwi.de/Redaktion/DE/Dossier/gaia-x.html>

Chen, H. (2019): Success Factors Impacting Artificial Intelligence Adoption - Perspective From the Telecom Industry in China. Dissertation, Virginia.

Chin-Chun, H.; Tan, K. C.; Zailani, H. M. S. und Vaidyanathan, J. (2013): Supply chain drivers that foster the development of green initiatives in an emerging economy. In: International Journal of Operations & Production Management, 33 (6), S. 656 – 688. ISSN 0144-3577. doi:10.1108/IJOPM-10-2011-0401

Danks, D. (2014): Learning. In: Frankish, K. und Ramsey, W.M., Hg. The Cambridge Handbook of Artificial Intelligence, Cambridge University Press, Cambridge, S. 151 – 167. ISBN 9781139046855.

Deloitte Consulting GmbH (2021): Carbon Analytics [online] – CO2 relevant optimization with machine learning and cloud technology [abgerufen am: 06.05.2021], verfügbar unter: <https://www2.deloitte.com/de/de/pages/technology/articles/carbon-analytics.html>

Deloitte Private (2021): Künstliche Intelligenz im Mittelstand. Deloitte [abgerufen am: 15.04.2021], verfügbar unter: <https://www2.deloitte.com/de/de/pages/mittelstand/contents/kuenstliche-intelligenz-im-mittelstand.html>

DIN EN ISO 50001:2018: Internationale Organisation für Normung, Energiemanagementsysteme, Beuth Verlag GmbH, Berlin.

eco - Verband der Internetwirtschaft e. V und Arthur D. Little (2020): Künstliche Intelligenz: Potenzial und nachhaltige Veränderung der Wirtschaft in Deutschland. eco - Verband der Internetwirtschaft e. V.; Arthur D. Little GmbH.

Eidam, B. (2020): Künstliche Intelligenz: 5 Schritte für eine Einführung mit System [online]. Digitale Exzellenz, 06.05.2020 [abgerufen am: 14.04.2021], verfügbar unter: <https://www.digitale-exzellenz.de/kunstliche-intelligenz-mit-system-einfuehren>

Fiber Engineering GmbH: Verfahren und Vorrichtung zur Herstellung von dreidimensional ausgeprägten Formteilen sowie Formteil. Erfinder: E. FÖRSTER. Anmeldung: 30. Mai 2003. Deutschland, DE: 103 24 735 B3.

Freitag, M.; Kück, M.; Alla, A. A. und Lütjen, M. (2015): Potenziale von Data Science in Produktion und Logistik: Teil 2 - Vorgehensweise zur Datenanalyse und Anwendungsbeispiele. In: Industrie 4.0 Management, 35 (6), 22 - 26.

GEDIA Automotive Group (2021): GEDIA [online] [abgerufen am: 06.05.2021], verfügbar unter: <https://www.gedia.com/de/>

Gemeinsam digital (2021): Das Mittelstand 4.0-Kompetenzzentrum Berlin [online]. Bundesverband mittelständische Wirtschaft, Unternehmerverband Deutschlands e.V. [abgerufen am: 05.05.2021], verfügbar unter: <https://gemeinsam-digital.de/>

Gestalt Robotics GmbH (2021): Der Dienstleister für intelligente Automatisierung [online], 03.05.2021, verfügbar unter: <https://www.gestalt-robotics.com/>

IANUS Simulation GmbH (2021): IANUS Simulation [online]. IANUS Simulation GmbH [abgerufen am: 06.05.2021], verfügbar unter: <https://ianus-simulation.de/>

Jones, N. (2018): The Information Factories. In: Nature, (561), S. 163 - 166.

Joshi, A. V. (2020): Machine learning and artificial intelligence, Springer, Cham, ISBN 978-3-030-26622-6.

Julius Zorn GmbH (2021): Juzo – Lebensfreude in Bewegung [online] [abgerufen am: 06.05.2021], verfügbar unter: <https://www.juzo.com/de>

juS.TECH AG (2021): Nachhaltige Digitalisierung beginnt hier: juS.TECH AG [online] [abgerufen am: 06.05.2021], verfügbar unter: <https://www.justech-ag.com/>

Kaack, L. H.; Donti, P. L.; Strubell, E. und Rolnick, D. (2020): Artificial Intelligence and Climate Change – Opportunities, considerations, and policy levers to align AI with climate change goals. Heinrich-Böll-Stiftung, Berlin [abgerufen am: 16.04.2021], verfügbar unter: <https://eu.boell.org/en/2020/12/03/artificial-intelligence-and-climate-change>

KAESER KOMPRESSOREN SE (2019): Sigma Air Manager 4.0: Technik von morgen schon heute [online], 11.03.2019 [abgerufen am: 06.05.2021], verfügbar unter: <https://www.kaeser.de/unternehmen/presse/pressemitteilungen/m-sigma-air-manager-4-0.aspx>

KI Bundesverband (2020): Deutschlands größtes KI-Netzwerk [online]. KI Bundesverband e.V. [abgerufen am: 05.05.2021], verfügbar unter: <https://ki-verband.de/>

Kosmol, J.; Kanthak, J.; Herrmann, F.; Golde, M.; Alsleben, C.; Penn-Bressel, G.; Schmitz, S. und Gromke, U. (2012): Glossar zum Ressourcenschutz. Umweltbundesamt, Dessau-Roßlau [abgerufen am: 15.04.2021], verfügbar unter: <https://www.umweltbundesamt.de/publikationen/glossar-ressourcenschutz>

Li, H.; Wang, Y.; Zhao, P.; Zhang, X. und Zhou, P. (2015): Cutting tool operational reliability prediction based on acoustic emission and logistic regression model. In: Journal of Intelligent Manufacturing, 26 (5), S. 923 – 931. Journal of Intelligent Manufacturing. doi:10.1007/s10845-014-0941-4

LUIS Technology GmbH (2021): LUIS Technology [online]. LUIS Technology GmbH [abgerufen am: 05.05.2021], verfügbar unter: <https://www.luis.de/>

Lundborg, M. und Märkel, C. (2019): Künstliche Intelligenz im Mittelstand – Relevanz, Anwendungen, Transfer. Begleitforschung Mittelstand-Digital WIK GmbH, Bad Honnef [abgerufen am: 16.04.2021], verfügbar

unter: <https://www.mittelstand-digital.de/MD/Redaktion/DE/Publikationen/kuenstliche-intelligenz-im-mittelstand.html>

LUVIS AI GmbH (2021): Deep Learning [online] – Lösungen die zu ihren Anforderungen passen [abgerufen am: 05.05.2021], verfügbar unter: <https://luvis.ai/>

M+S Silicon GmbH & Co. KG (2021): M+S Gruppe [online]. M+S Silicon GmbH & Co. KG [abgerufen am: 06.05.2021], verfügbar unter: <https://www.ms-silicon.de/ms-sil/>

Marcus, G. (2020): The Next Decade in AI: Four Steps Towards Robust Artificial Intelligence, verfügbar unter: <https://arxiv.org/pdf/2002.06177>

Mathur, D.; Ahmad, Z. und Chamuah, A. (2020): Artificial Intelligence for Sustainability. Friedrich-Ebert-Stiftung India, 8.

Meyer, M.; Frank, M.; Massmann, M.; Wendt, N. und Dumitrescu, R. (2020): Data-Driven Product Generation and Retrofit Planning. In: Procedia CIRP, 93, S. 965 – 970. ISSN 2212-8271. doi:10.1016/j.procir.2020.04.122

Meyes, R.; Donauer, J.; Schmeing, A. und Meisen, T. (2019): A Recurrent Neural Network Architecture for Failure Prediction in Deep Drawing Sensory Time Series Data. In: Procedia Manufacturing, (34), 789 – 797. ISSN 2351-9789. doi:10.18154/RWTH-2020-09588

Mittelstand 4.0 Kompetenzzentrum Dortmund (2020): Künstliche Intelligenz im Mittelstand - Potenziale und Anwendungsbeispiele. EffizienzCluster Management GmbH.

Moll, P.; Schäfer, A.; Coutandin, S. und Fleischer, J. (2019): Method for the Investigation of Mold Filling in the Fiber Injection Molding Process Based on Image Processing. In: Procedia CIRP, 86, S. 156 – 161. ISSN 2212-8271. doi:10.1016/j.procir.2020.01.012

Newborn, M. (2003): Deep Blue – An artificial intelligence milestone, Springer, New York, ISBN 978-0387954615.

Porter, M. E. (1985): Competitive advantage – Creating and sustaining superior performance, Free Press, New York, ISBN 0029250900.

Presse- und Informationsamt der Bundesregierung (2021): Datenstrategie der Bundesregierung – Eine Innovationsstrategie für gesellschaftlichen Fortschritt und nachhaltiges Wachstum. Bundeskanzleramt [abgerufen am: 16.04.2021], verfügbar unter: <https://www.bundesregierung.de/breg-de/suche/datenstrategie-der-bundesregierung-1845632>

Provost, F. und Fawcett, T. (2013): Data science for business – What you need to know about data mining and data-analytic thinking, O'Reilly Media, Sebastopol, CA, ISBN 9781449374297.

Rakova, B.; Yang, J.; Cramer, H. und Chowdhury, R. (2021): Where Responsible AI meets Reality: Practitioner Perspectives on Enablers for shifting Organizational Practices. Association for Computing Machinery, Proceedings of the ACM on Human-Computer Interaction, 7.

Rippel, D.; Lütjen, M. und Scholz-Reiter, B. (2014): A framework for the quality-oriented design of micro manufacturing process chains. In: Journal of Manufacturing Technology Management, 25 (7), S. 1028 – 1048. Journal of Manufacturing Technology Management. doi:10.1108/JMTM-11-2012-0110

Schebek, L.; Abele, E.; Campitelli, A.; Becker, B. und Joshi, M. (2016): Praxisleitfaden: Ressourceneffizienz in der Produktion – Zerspanungsprozesse. Hessen Trade & Invest GmbH, Wiesbaden.

Schoonhoven, J. J.; Roelands, M. und Brenna, F. (2019): Nach dem Hype: Was Führungskräfte über die erfolgreiche Implementierung künstlicher Intelligenz wissen müssen. IBM Services.

Schössler, M. und Ebel, G. (2019): KI-Plattformen als neue Marktgestalter – Eine strategische Herausforderung für Europas Wirtschaftspolitik. Friedrich-Ebert-Stiftung, Abteilung Wirtschafts- und Sozialpolitik, Bonn, WISO direkt.

Seifert, I.; Bürger, M.; Wangler, L.; Christmann-Budian, S.; Rohde, M.; Gabriel, P. und Zinke, G. (2018): Potenziale der Künstlichen Intelligenz im produzierenden Gewerbe in Deutschland. Begleitforschung PAICE; iit-Institut für Innovation und Technik in der VDI / VDE Innovation + Technik GmbH, Berlin [abgerufen am: 15.04.2021], verfügbar unter:

<https://www.bmwi.de/Redaktion/DE/Publikationen/Studien/potenziale-kuenstlichen-intelligenz-im-produzierenden-gewerbe-in-deutschland.html>

Senior, A. W.; Evans, R.; Jumper, J.; Kirkpatrick, J.; Sifre, L.; Green, T.; Qin, C.; Žídek, A.; Nelson, A. W. R.; Bridgland, A.; Penedones, H.; Petersen, S.; Simonyan, K.; Crossan, S.; Kohli, P.; Jones, D. T.; Silver, D.; Kavukcuoglu, K. und Hassabis, D. (2020): Improved protein structure prediction using potentials from deep learning. In: *Nature*, 577 (7792), S. 706 - 710. *Nature*. doi:10.1038/s41586-019-1923-7

Spreiter, L.; Witte, K.; Just, V.; Damm, P.; Bohnhoff, T.; Rahtgens, C.; Asanger, F.; Maas, S.; Britsch, C. und Förstner, F. (2021): Wie Künstliche Intelligenz Klimaschutz und Nachhaltigkeit fördern kann. KI Bundesverband e.V., Berlin.

Stadtreinigung Hamburg (2021): Stadtreinigung Hamburg [online]. Stadtreinigung Hamburg [abgerufen am: 05.05.2021], verfügbar unter: <https://www.stadtreinigung.hamburg/>

Statistisches Bundesamt (2017): Produzierendes Gewerbe - Kostenstruktur der Unternehmen des Verarbeitenden Gewerbes sowie des Bergbaus und der Gewinnung von Steinen und Erden. Statistisches Bundesamt, Fachserie 4, 4.3 [abgerufen am: 05.05.2021], verfügbar unter: <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Industrie-Verarbeitendes-Gewerbe/Publikationen/Downloads-Struktur/kostenstruktur-2040430177004.html>

Streibich, K.-H. und Zeller, M. (2019): Offene Plattformen als Erfolgsfaktoren für Künstliche Intelligenz. In: Buxmann, P. und Schmidt, H., Hg. *Künstliche Intelligenz*, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 107 - 117. ISBN 978-3-662-57567-3.

Tebaldi, L.; Di Maria, G.; Volpi, A.; Montanari, R. und Bottani, E. (2021): Economic evaluation of automated guided vehicles usage in a food company. In: *Procedia Computer Science*, 180, S. 1034 - 1041. ISSN 18770509. doi:10.1016/j.procs.2021.01.352

Umweltbundesamt (2020a): Indikator: Gesamtrohstoffproduktivität. [online]. UBA, 18.12.2020 [abgerufen am: 25.03.2021], verfügbar unter:

<https://www.umweltbundesamt.de/daten/umweltindikatoren/indikator-gesamtrohstoffproduktivitaet#die-wichtigsten-fakten>

Umweltbundesamt (2020b): Rohstoffproduktivität [online]. UBA, 18.06.2020 [abgerufen am: 25.03.2021], verfügbar unter: <https://www.umweltbundesamt.de/daten/ressourcen-abfall/rohstoffe-als-ressource/rohstoffproduktivitaet#entwicklung-der-rohstoffproduktivitaet>

Umweltbundesamt (2021): Emissionsquellen [online]. UBA, 30.07.2020 [abgerufen am: 25.03.2021], verfügbar unter: <https://www.umweltbundesamt.de/themen/klima-energie/treibhausgas-emissionen/emissionsquellen#energie-stationar>

Uren, V. (2020): Critical Success Factors for Artificial Intelligence Projects. EurOMA Conference 2020: Managing Operations for Impact, Warwick [abgerufen am: 16.04.2021], verfügbar unter: <https://research.aston.ac.uk/en/publications/critical-success-factors-for-artificial-intelligence-projects>

van Buren, E.; Chew, B. und Eggers, W. (2020): AI readiness for government - Are you ready for AI? Deloitte Insights.

VDI 4800 Blatt 1:2016-02: Verein Deutscher Ingenieure e.V., Ressourceneffizienz - Methodische Grundlagen, Prinzipien und Strategien, Beuth Verlag GmbH, Berlin.

VDI 4800 Blatt 1:2016-02: Verein Deutscher Ingenieure e.V., Ressourceneffizienz - Methodische Grundlagen, Prinzipien und Strategien, Beuth Verlag GmbH, Berlin.

VDI 4801:2018-03: Verein Deutscher Ingenieure e.V., Ressourceneffizienz in kleinen und mittleren Unternehmen (KMU), Beuth Verlag GmbH, Berlin.

VDI Zentrum Ressourceneffizienz (2017): Ressourceneffizienz durch Industrie 4.0 - Potenziale für KMU des verarbeitenden Gewerbes. VDI Zentrum Ressourceneffizienz GmbH, Berlin.

VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik (2019): Maschinelles Lernen - Künstliche Intelligenz mit neuronalen Netzen in optischen Mess- und Prüfsystemen. VDI Verein Deutscher Ingenieure e. V., Berlin.

VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik (2020):

Maschinelles Lernen in KMU – Künstliche Intelligenz im eigenen Unternehmen nutzen. VDI Verein Deutscher Ingenieure e. V., Berlin.

Vinuesa, R.; Azizpour, H.; Leite, I.; Balaam, M.; Dignum, V.; Domisch, S.; Felländer, A.; Langhans, S. D.; Tegmark, M. und Fuso Nerini, F. (2020): The role of artificial intelligence in achieving the Sustainable Development Goals. In: Nature communications, 11 (233), S. 1-10. Nature communications. doi:10.1038/s41467-019-14108-y

Wangermann, T. (2020): KI in KMU – Rahmenbedingungen für die Transformation von KI-Anwendungen in kleine und mittlere Unternehmen. Konrad-Adenauer-Stiftung e. V, Berlin, Analysen & Argumente, 381 [abgerufen am: 19.04.2021], verfügbar unter: <https://www.kas.de/de/analysen-und-argumente/detail/-/content/ki-in-kmu>

Weichenthal, S.; Hatzopoulou, M. und Brauer, M. (2019): A picture tells a thousand...exposures: Opportunities and challenges of deep learning image analyses in exposure science and environmental epidemiology. In: Environment international, 122, S. 3-10. Environment international. doi:10.1016/j.envint.2018.11.042

Werner-von-Siemens Centre for Industry and Science e.V. (2021): Industrie- und Wissenschaftscampus [online] [abgerufen am: 03.05.2021], verfügbar unter: <https://wvsc.berlin/>

Witte, K. und Gradl, M. (2021): Erfolgsfaktoren und Hindernisse mittelständischer Unternehmer/innen im Umgang mit KI: Erkenntnisse der KI-Sprechstunde. Humboldt Institut für Internet und Gesellschaft, Berlin.

Yu, C.-M.; Kuo, C.-J. und Chung, C.-T. (2016): Exploit the value of production data to discover opportunities for saving power consumption by production tools. In: International Symposium on Semiconductor Manufacturing (ISSM), 2016. Proceedings of technical papers : December 12-13, 2016, KFC Hall, Tokyo, Japan, IEEE, Piscataway, NJ, S. 1 - 4. ISBN 978-1-5090-4511-2.

ANHANG A: ÜBERSICHT IN DER PRAXIS GÄNGIGER KI-METHODEN

Tabelle 33: Zusammenstellung von in der Praxis etablierten Aufgabengebieten der künstlichen Intelligenz mit einer Auswahl an KI-Methoden

Kategorie	Aufgabengebiet	Methode	
Maschinelles Lernen	Trendanalyse	Lineare Regression	
		Nichtlineare Regression	
	Klassifizierung	Support Vector Machines	
		Logistische Regression	
		Decision Trees	
		Naive Bayes Classification	
	Segmentierung	Support Vector Clustering	
		K-means Clustering	
	Dimensionsreduktion	Hierarchical Clustering	
		Principal Component Analysis	
	Anomalieerkennung	Isolation Forest	
		Local Outlier Factor	
	Deep Learning	Bild- & Objekterkennung	Convolutional Neural Networks (CNN)
		Texterkennung	Convolutional Neural Networks (CNN)
Pattern Recognition			
Spracherkennung		Recurrent Neural Networks (RNN)	
		Long short-term Memory (LSTM)	
		Bidirectional Encoder Representations from Transformers (BERT)	
		Transformer	
Text- bzw. Sprachverständnis (engl. natural language understanding)		Recurrent Neural Networks (RNN)	
		Long short-term Memory (LSTM)	
		Bidirectional Encoder Representations from Transformers (BERT)	
	Transformer		
Text- bzw. Spracherzeugung (engl. natural language generation)	Markov chain		
	Recurrent Neural Networks (RNN)		
	Long short-term Memory (LSTM)		
		Transformer	

Kategorie		Aufgabengebiet	Methode
	Reinforcement Learning	Lernen in diskreten Umgebungen	Temporal Difference Control (Sarsa, Q-Learning)
		Lernen in stetigen Umgebungen	Deep Q-Network (DQN) Dueling Deep Q Network (DDQN)

ANHANG B: HYPOTHESEN DER EXPERTENBEFRAGUNG

Tabelle 34: Übersicht der aufgestellten Hypothesen

Kategorie	Hypothesen zum Einsatz von schwacher KI in KMU
Verbreitung von KI im Unternehmen	KI-Methoden sind noch nicht sehr verbreitet in KMU.
	In innovativen/IT-affinen Wirtschaftszweigen/Unternehmen sind KI-Methoden verbreiteter.
	KI wird schon recht weit verbreitet in Verwaltung/Management verwendet, jedoch bisher wenig in Fertigung und Produktion.
Anwendungsszenarien	Typische Anwendungsszenarien sind: Predictive Maintenance, Produktionsplanung, Prozessoptimierung Fertigung, Fehlererkennung und -vorhersage, Bedarfsplanung, Steigerung Energieeffizienz im Fertigungsprozess, Steigerung Energieeffizienz im Gebäudemanagement.
Reifegradmodell	Der Einsatz von KI findet sich nicht in der Unternehmensstrategie von KMU wieder.
	KMU des verarbeitenden Gewerbes fehlt grundsätzlich Fachwissen zur sinnvollen Einführung von KI.
Ressourceneffizienz	Durch den Einsatz von KI kann die Ressourceneffizienz in KMU gesteigert werden.
	Steigerung der Ressourceneffizienz ist kein Grund zur Einführung von KI.
	Quantifizierung von Ressourceneffizienz ist in Unternehmen kaum vorhanden.
	Anwendung von KI dient bisher hauptsächlich zur Steigerung der Wirtschaftlichkeit, kein Fokus auf Ressourcen/Umwelt.
	Die Nutzung von künstlicher Intelligenz ermöglicht KMU eine Verbesserung der Ressourceneffizienz.
Geschäftsmodelle	Ein Großteil der KMU ist sich nicht bewusst, dass der Einsatz von KI zu einer verbesserten Ressourceneffizienz führen kann.
	KMU sehen in der Anwendung von KI-Möglichkeiten, kurz- bis mittelfristig neue Geschäftsmodelle zu entwickeln.
	KMU sehen in der Anwendung von KI-Möglichkeiten, bestehende Geschäftsmodelle weiterzuentwickeln und zu optimieren.
Hemmnisse	KMU verfügen nicht über die benötigte Datengrundlage für den Einsatz von KI-Methoden.
	KMU benötigen Unterstützung bei der Einführung von KI-Methoden.
	Aus Sicht der KMU ist der Implementierungsaufwand von KI-Methoden zu groß.
	KMU verfügen nicht über ausreichende fachliche Kompetenzen.
Allg. Hypothesen	Für KMU ist der (wirtschaftliche) Nutzen nicht klar erkennbar.
	Die vorhandene technische Infrastruktur erschwert die Einführung von KI.
	Ein Großteil der KMU denkt derzeit über die Einführung von künstlicher Intelligenz nach.
	Aus Sicht der KMU ist die Definition von KI unklar.
	Aus Sicht der KMU ist die Integration verbesserter Technologien in bestehende Produktionslinien nicht/schwer möglich.
	KMU verfügen nicht über ausreichende Innovationsbereitschaft.
Für KMU ist die Identifikation geeigneter Technologien schwierig.	

ANHANG C: DIMENSIONEN DES REIFEGRADMODELLS

Tabelle 35: Ausprägungen des Reifegradmodells: KI-Strategie

Gering	Mittel	Hoch	Sehr Hoch
KI-Strategie			
<ul style="list-style-type: none"> • keine strategischen Ziele für den Einsatz von KI-Methoden • keine Angaben hinsichtlich des zielgerichteten Einsatzes von KI-Methoden und der erforderlichen Maßnahmen • keine Angaben hinsichtlich der erforderlichen strategischen Anpassungen der organisationalen Struktur 	<ul style="list-style-type: none"> • Daten und deren Analyse werden als geschäftsrelevant und erfolgskritisch bewertet • grobe bzw. oberflächliche Berücksichtigung des Einsatzes von KI im Rahmen strategischer Ziele • Sichtung und Prüfung der strategischen Bedeutung verfügbarer KI-Methoden einschließlich potenzieller, Auswirkungen auf org. Struktur und strategische Ziele und Maßnahmen • testweiser Einsatz von KI-Methoden im Rahmen von einzelnen Pilotanwendungen 	<ul style="list-style-type: none"> • eine dedizierte KI-Strategie ist Teil der Unternehmensstrategie • Daten und deren Analyse werden als geschäftsrelevant und erfolgskritisch bewertet • der Einsatz von KI-Methoden erfolgt mit Ausrichtung auf ausgewählte strategische Ziele • Bildung von Entscheidungs- und Expertengremien für die Beurteilung und den unternehmensweiten Einsatz von KI-Methoden • vereinzelter Einsatz von KI-Methoden und Datenanalysen • testweiser Einsatz von KI-Methoden im Rahmen von wenigen Use-Cases 	<ul style="list-style-type: none"> • eine dedizierte KI-Strategie ist direkt von der Unternehmensstrategie abgeleitet und in diese eingebettet • Definition von klaren Verantwortlichkeiten für die strategische Umsetzung der erforderlichen Maßnahmen • Definition von klaren Zielen und spezifischen Use-Cases über alle Unternehmensebenen und Bereiche • eindeutige Entscheidung für oder gegen den Einsatz von KI-Methoden in unterschiedlichen Unternehmensabteilungen

Tabelle 36: Ausprägungen des Reifegradmodells: Menschen

Gering	Mittel	Hoch	Sehr Hoch
Menschen			
<ul style="list-style-type: none"> Unternehmensstrukturen berücksichtigen keine auf den Einsatz von KI fokussierten oder neu zu entwickelnden Unternehmens- und Geschäftsbereiche untergeordnete Rolle von Fähigkeiten für die Anwendung von KI-Methoden im Rahmen des Rekrutierungsprozesses Fähigkeiten für die Anwendung von KI-Methoden der Mitarbeitenden sind nicht oder nur begrenzt vorhanden vereinzelte interne Ausbildungsangebote für KI-Fähigkeiten 	<ul style="list-style-type: none"> einzelne Mitarbeitende / Abteilungen beschäftigen sich weitestgehend losgelöst von der restlichen Nutzung mit dem Einsatz von KI-Methoden Berücksichtigung ausgewählter Fähigkeiten für den Einsatz bzw. die Entwicklung von KI-Methoden im Rahmen des Rekrutierungsprozesses Mitarbeitenden ist der Nutzen von Daten und deren Auswertung mithilfe von KI-Methoden zum Teil bewusst Weiterbildungsangebote für KI-Fähigkeiten für ausgewählte Mitarbeitende Anpassungen der organisationalen Struktur sind vorgesehen, jedoch nicht oder nur in sehr geringem Maße auf die effektive Nutzung von KI ausgerichtet 	<ul style="list-style-type: none"> Unternehmensstrukturen sind an den möglichen Einsatz von KI angepasst Berücksichtigung von rollenspezifischen KI-Fähigkeiten (z. B. Data Scientist, Data Engineer) und Definition von Grundanforderungen dem Großteil der Mitarbeitenden ist der Nutzen von Daten und deren Auswertung mithilfe von KI-Methoden weitestgehend bewusst ausgewählte Weiterbildungsangebote für KI-Fähigkeiten stehen dem Großteil der Mitarbeitenden zur Verfügung 	<ul style="list-style-type: none"> Unternehmensstrukturen sind basierend auf der Nutzung von KI definiert und untrennbar mit menschlichen Arbeitsabläufen verflochten Anforderungen für effektive und zielgerichtete Nutzung von KI sind zentraler Bestandteil der Anpassungen der Unternehmensstrukturen Ausrichtung des Rekrutierungsprozesses auf anwendungsbezogene und Use-Case spezifische Fähigkeiten allen Mitarbeitenden stehen umfassend genutzte Weiterbildungsangebote für KI-Fähigkeiten zur freiwilligen und verpflichtenden Nutzung zur Verfügung

Tabelle 37: Ausprägungen des Reifegradmodells: Prozesse

Gering	Mittel	Hoch	Sehr Hoch
Prozesse			
<ul style="list-style-type: none"> keine von KI-Methoden unterstützten Prozesse 	<ul style="list-style-type: none"> Prozesse sind teilweise durch KI-Methoden unterstützt es werden keine Kennzahlen für die Beurteilung von Profitabilität, Prozessstabilität und Prozessqualität erhoben 	<ul style="list-style-type: none"> Prozesse werden durch KI-Methoden unterstützt Kennzahlen für die Beurteilung von Profitabilität, Prozessstabilität und Prozessqualität werden erhoben 	<ul style="list-style-type: none"> KI-Methoden treiben die Weiterentwicklung der Prozesse voran

Tabelle 38: Ausprägungen des Reifegradmodells: Daten

Gering	Mittel	Hoch	Sehr Hoch
Daten			
<ul style="list-style-type: none"> • keine dedizierte Strategie für den Umgang mit allen im Unternehmen existierenden Daten • keine expliziten / impliziten Verantwortlichkeiten für den Umgang mit Daten • nur bedarfsbezogene und isolierte Datenerfassung • keine automatisierte und systematische Datenerfassung und Analyse • keine Verknüpfung von Datenquellen • Berücksichtigung von grundlegenden gesetzlichen und regulatorischen Datenschutzerfordernungen • geringe Bedeutung von Transparenz und Erklärbarkeit genutzter Daten und KI-Methoden 	<ul style="list-style-type: none"> • oberflächliche, strategische Verankerung des Umgangs mit allen im Unternehmen existierenden Daten • Verantwortung für den Umgang mit Daten ist als Teilaufgabe einem Mitglied des Vorstandes (CDO) / der Geschäftsführung zugeordnet. • Datenerfassung und -analyse erfolgen zum Teil automatisch und systematisch • Verknüpfung einzelner Datenquellen • Transparenz und Erklärbarkeit von Daten und KI-Methoden werden im Rahmen der Einsatzprüfung bzw. des Entwicklungsprozesses gegenüber einem positiven Wertbeitrag bedingt berücksichtigt 	<ul style="list-style-type: none"> • breite strategische Verankerung des Umgangs mit allen im Unternehmen existierenden Daten • Verantwortung für den Umgang mit Daten ist eine von mehreren Hauptaufgaben und einem Mitglied des Vorstandes / der Geschäftsführung zugeordnet • bedarfsgerechte Verknüpfung von Datenquellen • Daten sind zum Teil in Echtzeit verfügbar • Transparenz und Erklärbarkeit von Daten und KI-Methoden werden im Rahmen der Einsatzprüfung bzw. des Entwicklungsprozesses als Grundanforderung berücksichtigt 	<ul style="list-style-type: none"> • tiefe strategische Verankerung des Umgangs mit allen im Unternehmen existierenden Daten • Verantwortung für den Umgang mit diesen Daten ist alleinige Hauptaufgabe eines Mitglieds des Vorstandes / der Geschäftsführung (CDO) • Berücksichtigung aller Datenschutzerfordernungen und darüber hinausgehende interne Regelungen • hohe Anforderungen an Transparenz und Erklärbarkeit des Vorgehens und der Ergebnisbildung im Rahmen der Nutzung von KI-Methoden • Transparenz und Erklärbarkeit der Daten und KI-Methoden gelten als erfolgskritisch

Tabelle 39: Ausprägungen des Reifegradmodells: Technologien und Plattformen

Gering	Mittel	Hoch	Sehr Hoch
Technologien & Plattformen			
<ul style="list-style-type: none"> • kein oder nur sporadischer Einsatz von KI-Methoden • fragmentierte IT-Landschaft 	<ul style="list-style-type: none"> • eingesetzte KI-Methoden werden individuell entwickelt bzw. zugekauft • keine Möglichkeit zur Anwendung eingesetzter Methoden oder zugekaufter Bausteine auf andere Use-Cases • eingesetzte KI-Methoden bzw. zugekaufte Bausteine sind in keine übergreifende Architektur eingegliedert 	<ul style="list-style-type: none"> • die eingesetzten KI-Methoden basieren auf modularen Konzepten, welche ähnlich einem Baukasten kombiniert werden können • eingesetzte KI-Methoden operieren alleinstehend und teilweise bereits vernetzt • Bewältigung von Leistungsbeschränkungen durch den Einsatz von Cloud-Infrastruktur 	<ul style="list-style-type: none"> • nahezu alle eingesetzten Methoden basieren auf vorbereiteten Methodens Werkzeugen, dadurch geringer Anpassungsbedarf in Vorbereitung des operativen Einsatzes • Einsatz von KI-Methoden von höchstem Innovationsgrad, Stabilität oder Industrialisierungsgrad • Use-Case-bezogener Einsatz von Cloud, Hybrid, On-Premise oder Edge Computing • Leistung, Verfügbarkeit und Sicherheit der IT-Systeme sind erfolgskritisch • Einsatz von internen Entwicklungen mit positivem ökonomischen und operativen Wertbeitrag, welche entscheidenden Wettbewerbsvorteil darstellen

VDI Zentrum Ressourceneffizienz GmbH (VDI ZRE)
Bülowstraße 78
10783 Berlin
Tel. +49 (0)30 2759506-0
zre-info@vdi.de
www.ressource-deutschland.de

