HOCHSCHULE RUHR WEST
UNIVERSITY OF APPLIED SCIENCES

**HOCHSCHULE RUHR WEST**

**TECHNISCHES PRODUKTIONSMANAGEMENT**

**MÜLHEIM A. D. RUHR**

**ABSCHLUSSARBEIT ZUR ERLANGUNG DES**

**AKADEMISCHEN TITELS MASTER OF SCIENCE (M.SC.)**

# EMPIRISCHE UNTERSUCHUNG ZUM STAND UND EINSATZPOTENZIAL GENERATIVER KÜNSTLICHER INTELLIGENZ IM MASCHINENBAU

| | |
|---|---|
| Erstprüfer: | Prof. Dr. Friedrich Morlock |
| Zweitprüfer: | M. Sc. Julian Grzywaczyk |
| Eingereicht am: | 31.10.2025 |

Amin Hamidi

Matrikelnummer: 10007659

**Inhaltsverzeichnis**

**Abbildungsverzeichnis ..... III**

**Tabellenverzeichnis ..... IV**

**Abkürzungsverzeichnis ..... V**

**1 Einleitung ..... 1**

**2 Grundlagen ..... 3**

2.1 Definition von Künstlicher Intelligenz ..... 3

2.2 Historische Entwicklung der Künstlichen Intelligenz ..... 4

2.2.1 Abgrenzung klassischer KI und generativer KI ..... 6

2.3 Generative Künstliche Intelligenz ..... 7

2.3.1 Funktionsweise generativer Sprachmodelle ..... 8

2.3.2 Funktionsweise früher generativer Modelle ..... 9

**3 Stand der Forschung ..... 11**

3.1 Systematische Literaturrecherche ..... 11

3.1.1 Analytischer Rahmen zur Systematisierung ..... 12

3.1.2 Methodik der systematischen Literaturrecherche ..... 12

3.1.3 Screening und Auswahl der Studien (nach PRISMA) ..... 14

**4 Ergebnisse der systematischen Literaturrecherche zum Stand der Forschung ..... 16**

4.1 Forschungsstand entlang des Produktentstehungsprozesses (PEP) ..... 16

4.1.1 Phase 1: Produktplanung ..... 17

4.1.2 Phase 2: Entwicklung & Konstruktion ..... 20

4.1.3 Phase 3: Arbeitsvorbereitung ..... 25

4.1.4 Phase 4: Produktion ..... 28

4.1.5 Phase 5: Serviceplanung ..... 31

4.1.6 Systematische Einordnung des Einsatzes generativer KI im PEP ..... 32

4.2 MTO-Modell ..... 34

4.2.1 Dimension Mensch ..... 35

4.2.2 Dimension Technik ..... 37

4.2.3 Dimension Organisation ..... 39

**5 Forschungsmodell ..... 40**

5.1 Hypothesenentwicklung und -Herleitung ..... 42

5.1.1 Nutzungshäufigkeit und subjektiver Kenntnisstand ..... 42
5.1.2 Objektiver Kenntnisstand und Vertrauen ..... 43
5.1.3 Vertrauen als vermittelnde variabel ..... 44
5.1.4 Anwendungsschwerpunkt generativer KI im Produktentstehungsprozess ..... 45
5.1.5 Unternehmensgröße und Nutzungshäufigkeit ..... 46

**6 Forschungsdesign ..... 47**
6.1 Fragenkonzeption und Operationalisierung der Variablen ..... 47
6.1.1 Themenblock 1: Demografie & Kontext ..... 48
6.1.2 Themenblock 2: Nutzungsstatus & Häufigkeit ..... 50
6.1.3 Themenblock 3: Einsatzfelder generativer KI ..... 51
6.1.4 Themenblock 4: Subjektiver Kenntnisstand ..... 54
6.1.5 Themenblock 5: Objektiver Kenntnisstand ..... 56
6.1.6 Themenblock 6: Einsatzpotenzial im Arbeitskontext ..... 57
6.1.7 Themenblock 7: Vertrauen & Risiko ..... 58
6.2 Datenerhebung ..... 59
6.3 Auswertungsverfahren ..... 60
6.3.1 Datenaufbereitung ..... 61
6.3.2 Deskriptive Statistik ..... 62
6.3.3 Inferenzstatistische Verfahren ..... 63

**7 Ergebnisse ..... 65**
7.1 Deskriptive Darstellung der Stichprobe ..... 67
7.2 Inferenzstatische Analyse ..... 75
7.2.1 Aktueller Stand und empirisch beobachtete Nutzung generativer KI im Maschinenbau ..... 91

**8 Ausblick ..... 94**

**Literaturverzeichnis ..... 98**

**Anhang A: Variablenverzeichnis / Kodierung ..... 111**

**Abbildungsverzeichnis**

*Abbildung 1: Forschungsfeld Künstlicher Intelligenz. (Wecke, 2025)* ..... 7
*Abbildung 2: Phasen des Produktentstehungsprozesses in Anlehnung an Prof. Dr. Morlock (2024)* ..... 16
*Abbildung 3: Themenfelder des Forschungsmodells* ..... 41
*Abbildung 4: Geschlechterverteilung der Stichprobe. Eigene Darstellung* ..... 67
*Abbildung 5: Altersverteilung der Stichprobe. Eigene Darstellung* ..... 68
*Abbildung 6: Berufserfahrung der Stichprobe. Eigene Darstellung* ..... 69
*Abbildung 7: Regionale Verteilung der Stichprobe. Eigene Darstellung* ..... 70
*Abbildung 8: Branchenverteilung der Stichprobe. Eigene Darstellung* ..... 71
*Abbildung 9: Rollenverteilung der Stichprobe. Eigene Darstellung.* ..... 72
*Abbildung 10: Technisch - Strategische Unterscheidung der Rollen. Eigene Darstellung.* ..... 73
*Abbildung 11: Verteilung der Unternehmensgröße. Eigene Darstellung.* ..... 74
*Abbildung 12: Nutzungsstatus der Stichprobe. Eigene Darstellung.* ..... 75
*Abbildung 13: Nutzungshäufigkeit. Eigene Darstellung.* ..... 76
*Abbildung 14: Relative Häufigkeitsverteilung der einzelnen Einsatzfelder. Eigene Darstellung* ..... 79
*Abbildung 15: Phasenverteilung des Einsatzes generativer KI im PEP. Eigene Darstellung.* 84
*Abbildung 16: Kalibrierungslücke (Quizscore / Kompetenzscore). Eigene Darstellung.* ..... 88
*Abbildung 17: Prioritäten der Stichprobe im Nutzungskontext generativer KI. Eigene Darstellung.* ..... 93

**Tabellenverzeichnis**

*Tabelle 1: Systematische Einordnung funktionaler Anwendungsfelder entlang des Produktentstehungsprozesses* ..... 32
*Tabelle 2: Eingesetzte generative KI-Werkzeuge aus der Literaturrecherche* ..... 33
*Tabelle 3: Variablenübersicht des Themenblocks "Demografie & Kontext". Eigene Darstellung* ..... 49
*Tabelle 4: Variablenübersicht des Themenblocks "Nutzungsstatus & Häufigkeit". Eigene Darstellung* ..... 51
*Tabelle 5: Variablenübersicht des Themenblocks "Einsatzfelder generativer KI" (Funktionssicht). Eigene Darstellung.* ..... 53
*Tabelle 6: Variablenverzeichnis des Themenblocks "Einsatzfelder generativer KI" (Prozesssicht). Eigene Darstellung.* ..... 54
*Tabelle 7: Variablenübersicht des Themenblocks "Subjektiver Kenntnisstand". Eigene Darstellung.* ..... 56
*Tabelle 8: Variablenübersicht des Themenblocks "Objektiver Kenntnisstand". Eigene Darstellung.* ..... 57
*Tabelle 9: Variablenübersicht des Themenblocks "Einsatzpotenzial im Arbeitskontext". Eigene Darstellung.* ..... 58
*Tabelle 10: Variablenübersicht des Themenblocks "Vertrauen & Risiko". Eigene Darstellung.* ..... 59

**Abkürzungsverzeichnis**

**AIGC** – Artificial Intelligence Generated Content

**BTMS** – Building Technology Management System

**CAPP-GPT** – Computer Aided Process Planning – Generative Pre-trained Transformer

**CNC** – Computerized Numerical Control

**DL** – Deep Learning

**FM** – Foundation Model

**GAD** – Generative Algorithmic Design

**GAN** – Generative Adversarial Network

**GPT** – Generative Pre-trained Transformer

**KI** – Künstliche Intelligenz

**LLM** – Large Language Model

**LoRA** – Low-Rank Adaptation

**ML** – Maschinelles Lernen

**MTO** – Mensch, Technik, Organisation

**PEP** – Produktentstehungsprozess

**PRISMA** – Preferred Reporting Items for Systematic Reviews and Meta-Analyses

**TAM** – Technology Acceptance Model

**TRIZ** – Theorie des erfinderischen Problemlösens

**VAE** – Variational Autoencoder

# 1 Einleitung

Kaum eine technologische Entwicklung hat in den vergangenen Jahren ein vergleichbares Maß an Aufmerksamkeit erfahren wie die generative Künstliche Intelligenz (KI). Modelle wie Chat GPT verdeutlichen eindrucksvoll die Leistungsfähigkeit dieser Technologie und werfen zugleich grundlegende Fragen nach ihren Auswirkungen auf die zukünftige Arbeitswelt auf. (Kinder et. al., 2024) Besonders im technischen Umfeld, etwa im Kontext von Maschinenbau, wird deutlich, dass generative KI längst über den Status eines Forschungstrends hinausgeht und sich zu einem potenziellen Werkzeug mit weitreichender Relevanz für den beruflichen Alltag von Ingenieur: innen entwickelt. (Shafiee, 2025; Kinder et. al., 2024) Bereits in der Produktentwicklung zeigt sich, dass der Einsatz generativer KI nicht mehr allein auf Effizienzsteigerung abzielt. Vielmehr unterstützt sie den Übergang von sequenziellen zu agilen, zielorientierten Entwicklungsprozessen und verändert damit die ingenieurtechnische Arbeitsweise grundlegend. (Gerhard et. al., 2025) Diese Entwicklung zeigt sich nicht nur in der Prozessgestaltung, sondern auch in der zunehmenden inhaltlichen Tiefe der Anwendungen. Generative KI findet dabei vermehrt Einsatz in Bereichen, die zuvor menschlicher Expertise vorbehalten waren, etwa bei der automatisierten Erstellung technischer Dokumentationen, der Generierung innovativer Lösungsansätze oder der Unterstützung kreativer Entwicklungsprozesse. (Shafiee, 2025)

Obwohl generative KI zunehmend Aufmerksamkeit in verschiedenen Disziplinen erfährt, befindet sich ihre Anwendung im ingenieurwissenschaftlichen Kontext noch in einem frühen Entwicklungsstadium. Der aktuelle Forschungsstand zeigt, dass bestehende Arbeiten vorwiegend theoretisch-konzeptionell oder technikorientiert ausgerichtet sind. Der Schwerpunkt liegt dabei auf der Beschreibung von Modellarchitekturen, algorithmischen Grundlagen und potenziellen Anwendungsfeldern, während empirische Untersuchungen, die den tatsächlichen Einsatz und Nutzen generativer KI in realen ingenieurwissenschaftlichen Arbeitsumgebungen erfassen, bislang unzureichend erforscht wurde. (Kretzschmar et. al., 2024) Zwar eröffnen die technologischen Fortschritte neue Möglichkeiten zur Steigerung von Innovationskraft und Produktivität, zugleich verdeutlichen sie jedoch auch das Spannungsfeld zwischen den Potenzialen und Herausforderungen, mit denen Unternehmen und Fachkräfte im Zusammenhang mit der Akzeptanz, dem Kompetenzaufbau sowie der Integration generativer KI in bestehende Arbeitsprozesse konfrontiert sind. (Shafiee, 2025; Kinder et. al., 2024)

Im Rahmen einer vorhergehenden Forschungsarbeit unter dem Titel *„Einsatzmöglichkeiten generativer Künstlicher Intelligenz im Produktentstehungsprozess – Wie verändert generative KI den Ingenieurberuf?“* wurden leitfadengestützte Interviews mit Expert: innen aus Industrie, Entwicklung und Projektmanagement durchgeführt. Ziel dieser Untersuchung war es, erste realitätsnahe Einblicke in die Wahrnehmung, Nutzung und Integration generativer KI im ingenieurtechnischen Arbeitsumfeld zu gewinnen. Die Ergebnisse zeigten ein differenziertes Bild. Während generative KI in einzelnen Bereichen bereits eingesetzt wird, herrscht vielerorts Zurückhaltung, sei es aufgrund von Unsicherheiten, mangelndem Knowhow oder ethischen Bedenken. Im Wesentlichen erkannten die Befragten zwar das Potenzial der Technologie, hielten sich jedoch aufgrund ihres frühen Entwicklungsstadiums noch mit einer breiten Akzeptanz zurück. Die Studie stellt damit einen frühen empirischen Ansatz dar, der die Perspektiven von Fachkräften aus der Praxis erfasst und deren Einschätzung zu Potenzialen, Risiken und Umsetzungserfahrungen dokumentiert. Durch diesen explorativen Zugang wurde ein qualitatives Verständnis darüber geschaffen, wie Ingenieur: innen den Einfluss generativer KI auf ihre Tätigkeiten, Arbeitsprozesse und Kompetenzanforderungen einschätzen. (Morlock et. al., 2025)

Vor diesem Hintergrund knüpft die vorliegende Masterarbeit an die gewonnen qualitativen Erkenntnisse an, verfolgt jedoch einen eigenständigen Ansatz. Aufbauend auf der explorativen Vorstudie wird eine quantitative Erhebung durchgeführt, um ein umfassendes und systematisch vergleichbares Bild über den aktuellen Stand des Einsatzes generativer KI im Maschinenbau zu gewinnen.

Im Mittelpunkt stehen die Fragen, wie Ingenieur: innen die Technologie wahrnehmen, in welchem Umfang sie bereits genutzt wird und welche Chancen sowie Risiken damit verbunden sind. Darüber hinaus wird untersucht, welche Kompetenzen für einen souveränen Umgang mit generativer KI erforderlich erscheinen und wie sich diese Einschätzungen in Bezug auf Vertrauen und wahrgenommenes Potenzial unterscheiden. Die Ergebnisse sollen bestehende qualitative Erkenntnisse nicht nur validieren und erweitern, sondern zugleich belastbare Hinweise für Wissenschaft und Praxis liefern, um den zukünftigen Umgang mit generativer KI im ingenieurtechnischen Arbeitsumfeld gezielt weiterzuentwickeln. Daraus ergeben sich zentrale Forschungsfragen, die den Rahmen dieser Arbeit bilden: Wie offen ist der Maschinenbau für den Einsatz generativer KI? In welchen Bereichen wird die Technologie bereits angewendet, und wo bestehen noch Vorbehalte oder Unsicherheiten? Darüber hinaus stellt sich die Frage, welche Kompetenzen Ingenieur: innen künftig benötigen, um diese Technologie souverän in ihre Arbeitsprozesse zu integrieren.

Zur Beantwortung dieser Forschungsfragen werden zunächst die theoretischen Grundlagen sowie zentralen Konzepte und Modelle zum Einsatz generativer KI im ingenieurtechnischen Kontext vorgestellt. Anschließend wird das methodische Vorgehen der Untersuchung erläutert, wobei der Schwerpunkt auf der Entwicklung und Durchführung der quantitativen Erhebung liegt. Es folgt die Darstellung und Auswertung der erhobenen Daten, deren Ergebnisse im Kontext bestehender Forschung und praktischer Implikationen diskutiert werden. Den Abschluss der Arbeit bildet ein Ausblick der zentralen Erkenntnisse, zukünftige Entwicklungen sowie mögliche Forschungsperspektiven.

## 2 Grundlagen

Der folgende Abschnitt widmet sich den theoretischen Grundlagen der Künstlichen Intelligenz und schafft damit das Fundament für die weitere Arbeit. Ziel ist es, ein fundiertes Verständnis der Entstehung, der zentralen Definitionen und der technologischen Entwicklung von KI zu vermitteln. Dabei werden wesentliche Meilensteine in der Forschung und technische Fortschritte nachgezeichnet, die den Weg zur heutigen generativen KI bereitet haben. Diese Einordnung ermöglicht es, den gegenwärtigen Stand der Technologie besser zu verstehen und zugleich das Potenzial sowie die Herausforderungen zu erkennen, die sich für deren zukünftigen Einsatz im ingenieurtechnischen Umfeld ergeben.

### 2.1 Definition von Künstlicher Intelligenz

Die genaue Definition von Künstlicher Intelligenz ist sowohl innerhalb der Forschung als auch für Außenstehende schwer zu fassen. Dies liegt vor allem daran, dass der Begriff der Intelligenz selbst nicht einheitlich definiert ist und die Auffassung darüber, was Intelligenz genau ausmacht, stark variiert. Ein Vergleich zwischen menschlicher und künstlicher Intelligenz setzt voraus, dass sich der Intelligenzbegriff in angemessener Weise auf maschinelle Systeme übertragen lässt, was bislang nur eingeschränkt möglich ist. (Wang, 2019)

Der wissenschaftliche Diskurs beschreibt Künstliche Intelligenz in der Regel aus der funktionalen Perspektive. Damit sind Systeme gemeint, die Aufgaben übernehmen, die üblicherweise menschliches Denken, Lernen oder Wahrnehmung voraussetzen. So wird die Künstliche Intelligenz unter anderem als die Fähigkeit technischer Systeme verstanden, ihre Umwelt durch Datenaufnahme wahrzunehmen, diese Informationen zu interpretieren, Schlussfolgerungen zu ziehen und auf dieser Basis Handlungen auszuwählen, um bestimmte Ziele zu erreichen. Solche Systeme sind zudem in der Lage, ihr Verhalten durch Rückkopplungen mit der Umwelt kontinuierlich anzupassen. (Huang & Peissl, 2023) Andere wissenschaftliche Arbeiten betonen, dass

moderne KI-Systeme darauf ausgelegt sind, zentrale kognitive Prozesse des Menschen wie Lernen, Problemlösen, Wahrnehmung und die Interaktion mit ihrer Umwelt funktional zu modellieren, um dadurch eine eigenständige, generative Fähigkeit zur Analyse, Synthese und Entscheidungsfindung zu ermöglichen. (Gupta et. al., 2025) Den historischen Ausgangspunkt bildet jedoch die Definition von John McCarthy, einem der Pioniere des Fachgebiets. Er prägte den Begriff Künstliche Intelligenz bereits 1955 und beschrieb das Ziel dieser Disziplin darin, Maschinen zu entwickeln, die sich so verhalten, als verfügten sie über menschliche Intelligenz. Diese frühe Formulierung verdeutlicht, dass es nicht um eine vollständige Gleichsetzung mit menschlicher Intelligenz geht, sondern um die Entwicklung technischer Systeme, die in der Lage sind, komplexe Aufgaben in Anlehnung an menschliche Fähigkeiten zu bewältigen. (Ertel, 2016)

Aus diesen funktionalen und historischen Annäherungen ergibt sich ein Verständnis von Künstlicher Intelligenz als technologisches Feld, das einerseits auf die Nachbildung und andererseits auf die Erweiterung menschlicher kognitiver Prozesse abzielt. Dadurch wird ein Rahmen geschaffen, der es erlaubt, die unterschiedlichen Strömungen und Spezialisierungen innerhalb der KI, von wissensbasierten Systemen bis hin zu heutigen generativen Verfahren in ihrer Bedeutung und Entwicklung einzuordnen.

### 2.2 Historische Entwicklung der Künstlichen Intelligenz

Die historische Entwicklung der Künstlichen Intelligenz ist eng mit dem menschlichen Bestreben verbunden, Maschinen mit Fähigkeiten auszustatten, die dem menschlichen Denken und Handeln ähneln. Erste gedankliche Ansätze hierzu lassen sich bereits in der Antike finden, als Philosophen wie Aristoteles die Grundlage der formalen Logik entwickelte und über mechanische Hilfsmittel zur Problemlösung nachdachte. Diese frühen Überlegungen legten das theoretische Fundament für spätere Konzepte, die in der modernen Forschung und Entwicklung der Künstlichen Intelligenz eine konkrete Ausgestaltung gefunden haben. (Kakas, 2025)

Von besonderer Bedeutung ist in diesem Zusammenhang die Arbeit von Gottfried Wilhelm Leibniz, der im 17. Jahrhundert die Vision einer universellen Rechenmaschine entwickelte. Seine Idee zielte darauf ab, logische Schlussfolgerungen und komplexe Denkprozesse durch mechanische Verfahren abbildbar zu machen und damit einen wesentlichen theoretischen Grundstein für die spätere Entwicklung der Informatik zu legen. (Mainzer, 2019)

Ein entscheidender Fortschritt in der Entwicklung der Künstlichen Intelligenz erfolgte im 20. Jahrhundert mit dem Aufkommen moderner Computertechnologien. Alan M. Turing legte in

den 1930er- und 1940er- Jahren mit der Turing-Maschine ein abstraktes Modell vor, das zentrale Konzepte wie Algorithmus, Programm und Berechenbarkeit definierte und bis heute als grundlegendes Fundament der theoretischen Informatik gilt. (Ertel, 2016) Einen weiteren bedeutenden Beitrag leistete Turing im Jahr 1950 mit seinem Artikel *Computing Maschinery and Intelligence*, in dem er die wegweisende Frage *„Can machines think?“* aufwarf. (Turing, 1950) Als eigentliche Geburtsstunde der Künstlichen Intelligenz gilt jedoch die Dartmouth Konferenz von 1956. Wo John McCarthy in einem Forschungsantrag erstmals den Begriff *„Artificial Intelligence“* formulierte und damit die Grundlage für eine institutionalisierte Forschung schuf. Ziel war es, die Mechanismen menschlicher Intelligenz so präzise zu beschreiben, dass sie in einer Maschine nachgebildet werden konnte. Diese war von großem Optimismus geprägt und legte den Grundstein für erste Anwendungen symbolischer Systeme und Expertensysteme. (Mainzer, 2019)

In den 1960er- und 1970er- Jahren erlebte die Forschung zur Künstlichen Intelligenz eine Phase intensiver Weiterentwicklung, insbesondere durch wissensbasierte Ansätze, die darauf abzielten, menschliches Expertenwissen in formale Strukturen zu überführen. Mit ELIZA (Weizenbaum, 1966) entstanden in dieser Zeit eines der ersten Programme, das mithilfe regelbasierter Mustererkennung einfache Gespräche führen konnte und damit als technischer Meilenstein der frühen Sprachverarbeitung galt (Al-Amin et. al., 2024). Diese Fortschritte weckten große Erwartungen, führten jedoch bald zu Ernüchterung. Ab den 1970er- Jahren zeigte sich, dass viele Systeme nur in eng abgegrenzten Anwendungsbereichen zuverlässig funktionieren, während komplexere Problemstellungen nicht bewältigt werden konnten. Die Diskrepanz zwischen den hohen Erwartungen und den tatsächlichen Ergebnissen führte in den 1980er- und 1990er- Jahren zu wiederkehrenden Krisenphasen, die als sogenannter KI-Winter bekannt wurden. Diese Zeit war durch Kürzungen von Forschungsförderungen und ein Nachlassen des wissenschaftlichen Interesses geprägt, brachte jedoch zugleich neue Impulse hervor. Besonders die Expertensysteme der 1980er- Jahre zeigten, dass spezialisiertes Wissen in klar definierten Anwendungsfeldern erfolgreich nutzbar gemacht werden konnte. Gegen Ende dieser Phase entwickelten sich zudem neue rechnergestützte Paradigmen, die das Lernen aus Daten in den Vordergrund rückten und damit die Grundlage moderner maschineller Lernverfahren und neuronaler Netze bildeten. (Al-Amin et. al., 2024; IT-P GmbH, 2024)

Um die Jahrhundertwende markierte die zunehmende Rechenleistung und die Verfügbarkeit großer Datenmengen einen entscheidenden Wendepunkt in der Entwicklung der Künstlichen Intelligenz. Diese technologischen Fortschritte ermöglichten es, KI-Systeme nicht länger nur

als theoretisches Konzept zu begreifen, sondern sie in vielfältigen Anwendungsfeldern praktisch einzusetzen. Insbesondere führte die gesteigerte Prozessor- und GPU-Leistung, die Verfügbarkeit umfangreicher Datensätze und die Entwicklung effizienterer Lernalgorithmen dazu, dass KI-Modelle erstmals in großem Maßstab trainiert werden konnten. Bedeutende Erfolge, wie das System AlphaGo, das menschliche Spitzenkräfte in hochkomplexen Spielen übertraf, verdeutlichten eindrucksvoll das Potenzial dieser Technologie. Parallel dazu hielt Künstliche Intelligenz Einzug in Bereichen wie das Gesundheitswesen und die Automobilindustrie, wo sie sowohl diagnostische Verfahren unterstützte als auch autonome Fahrfunktionen ermöglichte. Heute gilt KI als Schlüsseltechnologie der Gegenwart. Ihre Anwendungsfelder reichen von digitalen Sprachassistenten wie Siri oder Alexa über autonome Transportsysteme bis hin zu generativen Modellen wie Chat GPT, die in der Lage sind, neue Inhalte zu erzeugen und kreative Prozesse zu unterstützen. Die Kombination aus leistungsstarker Hardware, Big Data und innovativen Modellarchitekturen, insbesondere der Transformer-Architektur, hat die Entwicklung der KI maßgeblich beschleunigt und bereitet den Boden für aktuelle Fortschritte im Bereich generativer Systeme. Gleichzeitig wirft diese Dynamik grundlegende ethische, rechtliche und gesellschaftliche Fragen auf, die den zukünftigen Umgang mit dieser Technologie entscheidend prägen werden. (Al-Amin et. al., 2024; IT-P GmbH, 2024)

### *2.2.1 Abgrenzung klassischer KI und generativer KI*

Im Anschluss an die historische Entwicklung der Künstlichen Intelligenz wird deutlich, dass sich das Verhältnis von Künstlicher Intelligenz im Laufe der Zeit gewandelt hat. Während frühe Ansätze vor allem auf der Nachbildung menschlicher Denkprozesse durch regel- und wissensbasierte Systeme lagen, eröffnete das Aufkommen datengetriebener Modelle neue Perspektiven. Insbesondere die generative KI markierte hierbei einen Paradigmenwechsel, da sie nicht mehr ausschließlich auf die Anwendung bestehenden Wissens ausgerichtet ist, sondern eigenständig neue Inhalte erzeugen kann. Klassische Ansätze der KI konzentrieren sich somit auf die Anwendung vordefinierter Regeln und Wissensbestände zur Lösung konkreter Aufgaben, während generative Systeme auf umfangreiche Datenmengen zurückgreifen, um Muster zu erkennen und daraus eigenständig neue Texte, Bilder oder andere Artefakte zu generieren. Der zentrale Unterschied liegt folglich in der Funktionalität. (Ronge et. al., 2025)

## 2.3 Generative Künstliche Intelligenz

An die Abgrenzung zur klassischen Künstlichen Intelligenz rückt nun die Betrachtung der generativen KI in den Mittelpunkt. Sie steht exemplarisch für den jüngsten Entwicklungsschritt innerhalb des breiten Feldes der Künstlichen Intelligenz und zeichnet sich dadurch aus, dass sie nicht mehr primär auf regelbasierte Problemlösung, sondern auf die kreative und kontextabhängige Generierung neuer Inhalte und Strukturen ausgerichtet ist. (Ronge et. al., 2025)

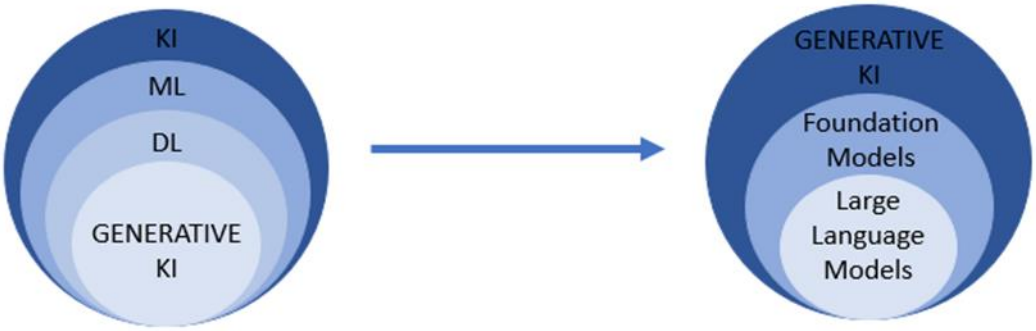


*Abbildung 1: Forschungsfeld Künstlicher Intelligenz. (Wecke, 2025)*

Die Einordnung der generativen Künstlichen Intelligenz innerhalb des gesamten Forschungsfelds wird in Abbildung 1 veranschaulicht. Generative KI stellt dabei einen eigenständigen Teilbereich dar, der auf den grundlegenden Konzepten des Maschinellen Lernens (ML) und des Deep Learnings (DL) aufbaut. Zugleich erweitert und vertieft sie die Ansätze, indem sie neue Verfahren zur selbstständigen Erzeugung von Daten, Inhalten und Modellen ermöglicht. Maschinelles Lernen (ML) bezeichnet Verfahren, bei denen Systeme in der Lage sind, aus Daten Muster abzuleiten und selbstständig Vorhersagen oder Entscheidungen zu treffen, ohne dass sie dafür explizit programmiert werden. Innerhalb dieses Bereiches nimmt das Deep Learning (DL) eine besondere Stellung ein, da es auf mehrschichtigen künstlichen neuronalen Netzen basiert. Diese Struktur ermöglicht es, auch hochkomplexe, unstrukturierte Daten wie Sprache, Bilder oder Sensordaten zu verarbeiten und mit hoher Präzision zu analysieren. Auf dieser Grundlage entsteht die generative KI als spezialisierter Zweig, dessen Ziel nicht nur die Analyse bestehender Informationen, sondern in der eigenständigen Erzeugung neuer Inhalte liegt. Dazu gehören die Generierung von Texten, Bildern, Musik oder Programmcode. Der wesentliche Fortschritt gegenüber klassischen KI-Systemen besteht darin, dass generative Modelle nicht ausschließlich reagierend oder regelbasiert agieren, sondern kreative Elemente einbringen und neue Kombinationen von Informationen hervorbringen können. Ein zentrales Konzept der generativen KI sind die sogenannten Foundation Models (FM). Diese Modelle sind auf enorme, häufig unstrukturierte Datenmengen trainiert und zeichnen sich durch ihre Vielseitigkeit aus. Sie lassen

sich für eine breite Palette von Aufgaben anpassen, wodurch sie eine hohe Flexibilität und Transferfähigkeit besitzen. Foundation Models bilden damit die Grundlage für viele aktuelle KI-Anwendungen und markieren einen qualitativen Sprung in der Entwicklung intelligenter Systeme. Eine spezialisierte Unterkategorie stellen die Large Language Models (LLMs) dar. Sie fokussieren die Verarbeitung und Generierung natürlicher Sprache und sind in der Lage, kohärente Texte zu erstellen, zu analysieren und zu interpretieren. Damit haben LLMs wie GPT-Modelle nicht nur die Forschung, sondern auch zahlreiche praktische Anwendungsfelder nachhaltig geprägt. Sie sind in der Lage, komplexe Sprachaufgaben zu bewältigen und können aufgrund ihrer breiten Einsetzbarkeit in unterschiedlichsten Domänen integriert werden. (Wecke, 2025)

### *2.3.1 Funktionsweise generativer Sprachmodelle*

Innerhalb der generativen Künstlichen Intelligenz bilden Large Language Models (LLMs) eine der zentralen technologischen Grundlagen. Ihr Ziel besteht darin, Sprache nicht nur zu verstehen, sondern auch eigenständig neue, inhaltlich stimmige und stilistisch konsistente Texte zu erzeugen. Diese Fähigkeit beruht auf tiefen neuronalen Netzarchitekturen, die aus einer Vielzahl künstlicher Neuronen bestehen, die in mehreren Schichten miteinander verbunden sind. Jedes Neuron empfängt Signale, verarbeitet sie anhand bestimmter Gewichtungen und gibt das Ergebnis an die nächste Ebene weiter. Auf diese Weise können LLMs sprachliche Muster, inhaltliche Beziehungen und komplexe Strukturen innerhalb großer Datenmengen erfassen und reproduzieren. Ein repräsentatives Beispiel für diese Modellklasse ist die GPT-Reihe (*Generative Pretrained Transformer*). Sie basiert auf der sogenannten Transformer-Architektur, die eine besondere Form der Informationsverarbeitung ermöglicht. Zentrales Element dieses Ansatzes ist der Mechanismus der Selbstaufmerksamkeit (*Self-Attention*), der dafür sorgt, dass das Modell relevante Textstellen kontextabhängig gewichtet und so auch über längere Distanzen hinweg Zusammenhänge erkennen kann. Dadurch gelingt es LLMs, sprachliche Kohärenz und thematische Konsistenz in ihren Ausgaben aufrechtzuerhalten, was sie von früheren, rein sequenziellen Modellen unterscheidet. Der Entwicklungsprozess eines LLM verläuft in mehreren Phasen. In einer umfangreichen Studie werden großen Mengen an Textdaten aus unterschiedlichen Quellen, wie wissenschaftlichen Publikationen, Fachbüchern oder Online-Diskurse, analysiert. Das Modell lernt dabei, Wahrscheinlichkeitsverteilungen sprachlicher Einheiten zu erfassen und Muster zwischen Wörtern, Sätzen und Themen zu erkennen. Nach Abschluss dieses Lernprozesses kann das Modell anhand eines sogenannten Prompts, also einer gezielten Eingabe oder Fragestellung, eigenständig Texte erzeugen. Die Ausgabe entsteht, indem das Modell

den wahrscheinlichsten Folgetoken berechnet und diesen iterativ zu einer vollständigen sprachlichen Einheit ergänzt. Die resultierenden Texte orientieren sich an der erlernten Syntax und stilistischen Vielfalt der Trainingsdaten. Ein entscheidender Aspekt für die Qualität der generierten Inhalte ist das sogenannte Prompting. Damit ist die Gestaltung der Eingabe gemeint, die die gewünschte Richtung der Ausgabe vorgibt. Je präziser der Prompt formuliert ist, desto genauer kann das Modell die intendierte Aufgabe umsetzen. Dabei sind eine klare Zieldefinition, die Beschreibung des Anwendungskontextes und spezifische Vorgaben wie Textlänge, thematische Schwerpunkte oder Tonalität von Bedeutung. Durch die Kombination dieser Parameter lässt sich die Generierung gezielt steuern. Zusätzlich können Beispieltexte als Orientierung dienen, wodurch die Kohärenz und inhaltliche Passgenauigkeit der Ergebnisse weiter gesteigert wird. Dadurch lässt sich festhalten, dass LLMs eine wesentliche Weiterentwicklung im Bereich der generativen KI darstellen. Sie verbinden datengetriebene Lernmechanismen mit der Fähigkeit zur kontextsensitiven Sprachproduktion und eröffnen dadurch neue Möglichkeiten für automatisierte Textgenerierung, Informationsverarbeitung und wissensbasierte Interaktionen. Ihre Adoptionsfähigkeit und Präzision machen sie zu einer Schlüsseltechnologie für zahlreiche Anwendungsfelder in Wissenschaft, Wirtschaft und Gesellschaft. (Wecke, 2025)

### *2.3.2 Funktionsweise früher generativer Modelle*

Die Entwicklung generativer Künstlicher Intelligenz vollzog sich schrittweise und lässt sich als evolutionärer Prozess beschreiben, der von frühen Modellarchitekturen bis hin zu heutigen Large Language Models (LLMs) reicht. Während LLMs als hochskalierte Systeme mit Milliarden von Parametern und enormen Datenmengen operieren, beruhen ihre konzeptionellen Grundlagen auf früheren generativen Ansätzen wie den Autoencodern, den Variational Autoencoders (VAEs) und den Generative Adversarial Networks (GANs). Diese Modelle legten das theoretische und methodische Fundament für die heutige Fähigkeit von KI-Systemen, eigenständig konsistente, kreative und kontextbezogene Inhalte zu erzeugen. Autoencoder stellen eine der frühsten Formen neuronaler Netze dar, die auf die Reduktion komplexer Datenstrukturen und die Extraktion bedeutungstragender Merkmale ausgerichtet sind. Ihre Architektur besteht aus einem Encoder, der Eingabedaten in eine latente, verdichtete Repräsentation überführt, und einem Decoder, der versucht, die ursprünglichen Daten aus dieser Repräsentation zu rekonstruieren. Dieser Prozess ermöglicht es, die zugrunde liegenden Muster und Strukturen der Daten zu erfassen und sie in einer komprimierten Form abzubilden. Autoencoder dienten ursprünglich der Dimensionsreduktion und Merkmalsextraktion, stellten jedoch gleichzeitig einen ersten Schritt zur generativen Modellierung dar, da sie ein grundlegendes Verständnis dafür

lieferten, wie Informationen in neuronalen Netzen kodiert und rekonstruiert werden können. (Goodfellow et. al., 2014) Aufbauend auf diesem Konzept wurde die Variational Autoencoders (VAEs) entwickelt, die das deterministische Prinzip klassischer Autoencoder um einen probabilistischen Ansatz erweitern. Während Autoencoder lediglich darauf abzielen, Eingabedaten möglichst präzise wiederherzustellen, modellieren VAEs die Datenverteilung selbst. Durch die Einführung eines stochastischen Elements im latenten Raum können sie neue, bisher nichtexistierende Datenpunkte generieren, die statistisch mit den Trainingsdaten übereinstimmen. Dies geschieht, indem das Modell für jede Eingabe die Parameter einer Wahrscheinlichkeitsverteilung bestimmt, aus der anschließend neue Datenpunkte gezogen und rekonstruiert werden. Diese probabilistische Struktur erlaubt nicht nur die Rekonstruktion, sondern auch die kontrollierte Erzeugung synthetischer Daten, wodurch VAEs einen entscheidenden Fortschritt in der Entwicklung generativer Verfahren darstellen. (Goodfellow et. al., 2014; Kingma et. al., 2014) Einen weiteren Meilenstein in der Evolution generativer Modelle markieren die Generative Adversarial Networks (GANs). Ihr zentrales Prinzip beruht auf einem gegnerischen Trainingsprozess, bei dem zwei neuronale Netze, der Generator (G) und der Diskriminator (D), in einer Art Wettstreit gegeneinander antreten. Der Generator versucht, synthetische Daten zu erzeugen, die nicht von realen Beispielen unterscheidbar sind, während der Diskriminator darauf trainiert wird, echte von künstlichen Daten zu unterscheiden. Mathematisch lässt sich dieses Zusammenspiel als Minimax-Optimierungsproblem beschreiben, bei dem beide Netzwerke iterativ verbessert werden. Das Ziel besteht darin, eine Situation zu erreichen, in der der Diskriminator keine Unterscheidung mehr treffen kann, weil die vom Generator erzeugten Daten die reale Verteilung nahezu perfekt abbilden. In der Gesamtschau bilden Autoencoder, VAEs und GANs die technologische Grundlage moderner generativer KI-Modelle. Sie etablieren Schlüsselprinzipien wie die Repräsentation latenter Merkmalsräume, die probabilistische Generierung neuer Daten und die gegnerische Optimierung durch konkurrierende Netzwerke. Diese Konzepte wurden in späteren Modellgenerationen weiterentwickelt und skaliert, wodurch die Entstehung der Foundation Models und in deren Folge die heutigen Large Language Models ermöglicht wurde. (Goodfellow et. al., 2014)

# 3 Stand der Forschung

Mit der Veröffentlichung von Chat GPT durch Open AI im November 2022 wurde generative Künstliche Intelligenz erstmals einer breiten Öffentlichkeit zugänglich gemacht und rückte dadurch stärker in den Fokus öffentlicher und gesellschaftlicher Aufmerksamkeit. Innerhalb kürzester Zeit ermöglichte die Anwendung einen intuitiven Zugang zur Nutzung generativer KI, bei dem Nutzer: innen in natürlicher Sprache mit dem System interagieren und in Sekundenschnelle verständliche Antworten erhalten konnten. Chat GPT ist dabei nur eine von mehreren Entwicklungen im Bereich der generativen KI, die seitdem in Forschung und Praxis vermehrt Beachtung finden. Auch die Industrie hat auf diesen technologischen Fortschritt reagiert, indem Unternehmen ein wachsendes Interesse daran zeigen, die Potenziale generativer KI zu erforschen und zu erproben, um den möglichen Nutzen dieser Systeme im eigenen betrieblichen Kontext zu bewerten. Im Vordergrund steht dabei weniger der unmittelbare produktive Einsatz, sondern vielmehr die strategische Auseinandersetzung mit den Anwendungsfeldern, Chancen und Grenzen generativer KI im industriellen Umfeld. (Büchel & Engel, 2024) Das stetig wachsende Angebot neuer Werkzeuge im Bereich der Künstlichen Intelligenz, insbesondere generativen Ansätze, führt in Unternehmen vermehrt zu der Frage, welche konkreten Potenziale diese Technologie bietet und in welchen spezifischen Anwendungsfeldern ihr Einsatz als sinnvoll und wirtschaftlich eingeschätzt werden kann. (Steininger et. al., 2024)

Um den Einfluss generativer KI-Modelle auf ingenieurtechnische Arbeitsprozesse jedoch fundiert einordnen und bewerten zu können, ist eine systematische Aufarbeitung des aktuellen wissenschaftlichen Erkenntnisstands unerlässlich. Es wird eine systematische Literaturrecherche durchgeführt, die den bisherigen Einsatz, die diskutierten Nutzenbeiträge sowie die identifizierten Grenzen generativer KI im Kontext des Maschinenbaus nachvollziehen und strukturieren soll.

## 3.1 Systematische Literaturrecherche

Die vorliegende Literaturrecherche verfolgt einen offenen und breit angelegten Ansatz, um ein umfassendes Bild der aktuellen Entwicklung an der Schnittstelle von generativer Künstlicher Intelligenz und Ingenieurwesen zu erfassen. Ziel ist es, die gegenwärtige wissenschaftliche und anwendungsorientierte Diskussion in ihrer gesamten Breite und Tiefe zu berücksichtigen. In die Analyse fließen unterschiedliche Arten von Informationsquellen ein, darunter empirische Studien, quantitative und qualitative Umfragen, theoretische Arbeiten sowie systematische Übersichtsartikel. Während praxisnahe Untersuchungen wertvolle Einblicke in den konkreten Einsatz generativer KI im ingenieurtechnischen Arbeitsprozess liefern, tragen konzeptionelle

Beiträge dazu bei, übergeordnete Zusammenhänge zu verstehen und bestehende Forschungslücken zu identifizieren. Durch die Verbindung beider Perspektiven wird gewährleistet, dass die Literaturrecherche sowohl wissenschaftliche Fundierung als auch praxisrelevante Anwendungsbezüge berücksichtigt. Dieser integrative Ansatz ermöglicht eine ganzheitliche Betrachtung des Themenfelds und bildet die Grundlage für eine fundierte Analyse der Potenziale, Herausforderungen und Grenzen generativer KI im Maschinenbau. Zugleich liefert er eine systematische Übersicht über den aktuellen Stand der Nutzung und Integration generativer KI in diesem Bereich.

### *3.1.1 Analytischer Rahmen zur Systematisierung*

Die im Rahmen der Literaturrecherche gewonnen Ergebnisse werden systematisch aufbereitet und in eine vergleichbare Form überführt, indem die identifizierten Einsatzmöglichkeiten generativer KI sowohl entlang der Phasen des Produktentstehungsprozesses als auch entlang der Dimensionen Mensch, Technik und Organisation (MTO-Modell) strukturiert werden. Dieses Vorgehen bildet den analytischen Rahmen der Arbeit und ermöglicht eine zweidimensionale Einordnung der Befunde. Einerseits wird die Integration generativer KI entlang des Produktentstehungsprozesses betrachtet, der als Abfolge von Aktivitäten von der Identifikation einer Marktchance bis zur Auslieferung des Produkts verstanden wird (Patil et. al., 2017). Andererseits erfolgt eine soziotechnische Perspektive, die die Wechselwirkungen zwischen individuellen, technischen und organisatorischen Faktoren berücksichtigt (Bendel & Latniak, 2023).
Dadurch kann der aktuelle Stand des Einsatzes generativer KI im Maschinenbau sowohl prozessual als auch ganzheitlich differenziert analysiert werden.

### *3.1.2 Methodik der systematischen Literaturrecherche*

Um die thematische Vielfalt der untersuchten Quellen gezielt und methodisch fundiert auszuwerten, wurde die Literaturrecherche auf Grundlage eines strukturierten und nachvollziehbaren Suchprozesses durchgeführt. Hierzu wurden mehrere einschlägige wissenschaftliche Datenbanken herangezogen, darunter IEEE Xplore, Science Direct, Springer Link und Research Gate. Ergänzend flossen praxisrelevante Quellen wie Whitepapers, Branchenstudien und technologische Leitfäden ein, insbesondere von Institutionen mit Bezug zum Maschinenbau und zur industriellen Forschung. Darüber hinaus wurde, sofern inhaltlich erforderlich, ausgewählte Peer-Review-Artikel, Pre-Prints sowie qualitativ geprüfte Online-Beiträge berücksichtigt, um ein möglichst vollständiges und aktuelles Bild des Forschungs- und Anwendungsstandes generativer KI im Maschinenbau zu gewährleisten.

Die Suchstrategie basiert auf einer systematischen Kombination deutsch- und englischsprachiger Schlagwörter, deren gezielte Verknüpfung mithilfe boolescher Operatoren (AND, OR) eine präzise und zugleich flexible Eingrenzung des Suchraums ermöglichte. Um die Inhaltliche Aktualität und Relevanz sicherzustellen, wurde der Analysezeitraum bewusst auf Publikationen ab dem Jahr 2022 begrenzt. Diese Entscheidung beruht auf den jüngsten und tiefgreifenden Fortschritten im Bereich leistungsfähiger generativer KI-Modelle, die auf der Transformer-Architektur basieren und seither Forschung und Anwendung im industriellen Kontext maßgeblich prägten. Zwar wurde die zugrunde liegende Technologie der Transformer-Architektur bereits 2017 erstmals vorgestellt und markierte damit einen entscheidenden Meilenstein in der Entwicklung generativer KI (Vaswani et. al., 2017). Der entscheidende Impuls für die breite öffentliche Wahrnehmung und Anwendung erfolgte jedoch erst durch die Veröffentlichung von Chat GPT durch Open AI im Jahr 2022. Dieses Ereignis machte die Potenziale generativer KI -Modelle erstmals einer breiten Öffentlichkeit unmittelbar sowie zu einer intensiveren wissenschaftlichen Auseinandersetzung mit KI-Systemen in Forschung und Praxis. Vor diesem Hintergrund wurde das Jahr 2022 als Ausgangspunkt der Untersuchung zum Stand der Forschung gewählt. (Steininger et. al., 2024)

Im Rahmen der Voruntersuchung wurde zunächst ein grundlegender Suchstring angewendet, bestehend aus den Schlüsselbegriffen *generative AI* und *mechanical engineering*. Diese Kombination vereint die beiden zentralen Themenfelder der Arbeit und dient dazu, einen ersten Überblick über die Breite und Verteilung der vorhandenen wissenschaftlichen Publikationen zu gewinnen. Bereits die Suchanfrage ergab eine erhebliche Anzahl an Treffern und verdeutlichte damit die thematische Relevanz des Forschungsfeldes. Die Suchabfrage ergab folgende Trefferzahlen in den herangezogenen Datenbanken: IEEE Xplore $n = 34$, ScienceDirect $n = 4062$, Springer Link $n = 127$, Research Gate $n = 14.220$ und ACM Digital Library $n = 20.961$.

Besonders in der Datenbank (*ScienceDirect)* lässt sich das wachsende Interesse an der Schnittstelle zwischen den Themenfeldern verdeutlichen, neben den 167 Beiträgen im Jahr 2022 ließ sich die Zahl der Publikationen im Jahr 2025 auf 2488 Beiträge erhöhen. Diese Entwicklung verdeutlicht die Dynamik des Forschungsfeldes und das rapide zunehmende Interesse an der Anwendung generativer KI im Maschinenbau. Gleichzeitig stellt die hohe Trefferzahl eine methodische Herausforderung dar, da sie eine gezielte Auswahl relevanter Arbeiten erschwert. Aus diesem Grund wurde in den besonders umfangreichen Datenbanken eine Optimierung vor-

genommen. Dazu kamen spezifische Filter und Suchparameter innerhalb der erweiterten Suchfunktionen zum Einsatz oder relevante Publikationen aus der anfänglichen Treffermenge wurden zur Anpassung des Suchstrings herangezogen. Auf dieser Grundlage konnten zentrale Schlüsselbegriffe und thematische Cluster identifiziert werden, um die ursprüngliche Trefferliste inhaltlich einzugrenzen. Ziel dieses Vorgehens war es, die Recherche zu fokussieren, die inhaltliche Schärfe der Untersuchung zu erhöhen und die Analyse auf die für die Arbeit relevanten wissenschaftlichen Beiträge auszurichten. In den Datenbanken IEEE Xplore und Springer Link war aufgrund der geringen Trefferzahl keine weiterführende Optimierung erforderlich. Schließlich konnte die anfängliche hohe Trefferzahl durch den Einsatz spezifischer Filter und Parameter in den Datenbanken ScienceDirect und ACM Digital Library auf $n = 354$ relevante Publikationen reduziert werden. In Research Gate war eine vergleichbare Eingrenzung nicht möglich, weshalb hier eine manuelle Identifikation relevanter Beiträge vorgenommen wurde.

### *3.1.3 Screening und Auswahl der Studien (nach PRISMA)*

Im Anschluss an die eingangs durchgeführte Literaturrecherche erfolgte die strukturierte Auswahl und Bewertung der identifizierten Publikationen nach dem PRISMA-Vorgehensmodells (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). Dieses Modell bildet den methodischen Rahmen für den mehrstufigen Auswahlprozess und gewährleistet eine transparente, nachvollziehbare und systematische Reduktion der anfänglichen ermittelten Treffer. Das anschließende Screening der Publikationen erfolgte zweistufig auf der Grundlage vordefinierter Ein- und Ausschlusskriterien, um die Relevanz und wissenschaftliche Qualität der Beiträge sicherzustellen. (Page et. al., 2021) Im ersten Schritt wurden sämtliche Titel und Abstracts gesichtet und hinsichtlich ihrer thematischen Passung überprüft. Eingeschlossen wurden Publikationen, die (i) einen eindeutigen Bezug zu generativer Künstlicher Intelligenz im Kontext des Ingenieurwesens beziehungsweise Maschinenbaus aufweisen, (ii) ab dem Jahr 2022 veröffentlicht wurden, (iii) in deutscher oder englischer Sprache erschienen sind und (iv) einen wissenschaftlichen Qualitätsanspruch, etwa durch Peer-Review-Verfahren darstellen.

Ausgeschlossen wurden hingegen Publikationen, die (i) keine generativen Verfahren adressieren, (ii) keinen inhaltlichen Bezug zum Maschinenbau aufweisen, (iii) nicht wissenschaftlicher Natur waren, beispielsweise Blogs- oder Magazinbeiträge, oder (iv) methodisch unzureichend dokumentiert wurden. Im Rahmen des Titel- und Abstract-Screenings wurden insgesamt etwa $n = 305$ Publikationen ausgeschlossen, sodass rund $n = 146$ Studien für die anschließende Volltextanalyse verblieben.

In dieser Phase wurden die ausgewählten Publikationen im Volltext eingehend analysiert und erneut den anhand der zuvor definierten Ein- und Ausschlusskriterien bewertet. Ausschlussgründe in dieser Stufe waren insbesondere eine fehlende methodische Transparenz, eine unzureichende Anwendungsnähe zum Maschinenbau oder eine thematische Auseinandersetzung ohne erkennbaren Bezug zum Produktentstehungsprozesses oder den MTO-Dimensionen.

Die im Rahmen der systematischen Literaturrecherche gewonnen Ergebnisse verdeutlichen, dass der Forschungsstand zur Anwendung generativer KI im Maschinenbau derzeit durch eine hohe Dynamik und eine ausgeprägte Anwendungsorientierung geprägt ist. Es zeigt sich ein heterogenes Forschungsfeld, das vor allem durch praxisnahe Einzelstudien dominiert wird, welche spezifische Einsatzfelder adressieren. Diese Beobachtungen führen zu der Schlussfolgerung, dass die Festlegung auf eine fixe Anzahl relevanter Studien (n) methodisch nicht zielführend wäre, da sie die Breite und Heterogenität des Forschungsfeldes unzureichend abbilden würde. Stattdessen begünstigt die vorgefundene Verteilung der Beiträge eine differenzierte und gezielt erweiterte Literatursuche, die neben der klassischen Datenbankrecherche auch anwendungsorientierte und graue Literatur einbezieht. Diese Vorgehensweise trägt der hohen Aktualität des Themas Rechnung und ermöglicht es, die in verschiedenen Veröffentlichungsformaten verstreuten Erkenntnisse systematisch zu erfassen und in den Gesamtkontext einzuordnen.

Die methodische Entscheidung wird durch aktuelle wissenschaftliche Arbeiten gestützt. Sie weisen auf eine fragmentierte und stark anwendungsgetriebene Forschungslandschaft zu generativer KI im Maschinenbau hin und betonen den Bedarf an einer systematischeren Aufbereitung der bestehenden Literatur. In einem aktuellen Review wird zudem ein deutliches Ungleichgewicht im Aufkommen der Publikationen nachgewiesen. Gleichzeitig zeigt sich in der grauen Literatur ein erheblicher Anteil relevanter Inhalte, die wichtige Erkenntnisse zur praktischen Anwendung generativer KI liefern. (Kakas, 2025; Berger, 2024)

Beide Arbeiten bekräftigen somit die gewählte Vorgehensweise, einer phasenübergreifende und systematisch strukturierte Literaturrecherche vorzunehmen, um den Forschungsstand zu generativer KI im Maschinenbau umfassend und aktuell abzubilden.

# 4 Ergebnisse der systematischen Literaturrecherche zum Stand der Forschung

Die nachfolgend dargestellten Ergebnisse basieren auf den im Rahmen der systematischen Literaturrecherche identifizierten und ausgewählten Studien. Ziel der Auswertung ist es, ein umfassendes und differenziertes Bild des aktuellen Forschungsstands sowie der Einsatzpotenziale generativer Künstlicher Intelligenz im Maschinenbau zu zeichnen. Die Befunde werden entlang des im vorangegangenen Kapitel beschriebenen analytischen Rahmens strukturiert und sowohl den Phasen des Produktentstehungsprozesses (PEP) als auch den Dimensionen des MTO-Modells zugeordnet. Auf diese Weise entsteht eine systematische Analyse, die technologische, menschliche und organisatorische Aspekte gleichermaßen berücksichtigt. Die Ergebnisse dienen nicht nur der Beschreibung des aktuellen Forschungsstands, sondern auch der Identifikation bestehender Forschungslücken, die für die weiterführende empirische Untersuchung dieser Arbeit von zentraler Bedeutung sind.

## 4.1 Forschungsstand entlang des Produktentstehungsprozesses (PEP)

Der Produktentstehungsprozess bildet ein zentrales Fundament industrieller Wertschöpfung und umfasst sämtliche Schritte von der ersten Idee bis zur Serienfertigung eines Produktes. Er stellt ein etabliertes Referenzmodell dar, das die Phasen der Produktplanung, Entwicklung und Konstruktion, Arbeitsvorbereitung, Produktion sowie Serviceplanung systematisch miteinander verknüpft. Damit bietet der Produktentstehungsprozess nicht nur eine strukturierende Orientierung für ingenieurtechnische Tätigkeiten, sondern zugleich einen klaren Bezugsrahmen, um Einsatzmöglichkeiten generativer KI entlang verschiedenen Entwicklungsstufen zu verorten. (Patil et. al., 2017) Die nachfolgende Abbildung veranschaulicht den Ablauf und die in diesem Zusammenhang relevanten fünf Phasen des Prozesses. Die methodische Gliederung des Produktentstehungsprozesses in fünf Phasen erfolgt in Anlehnung an das Modul Fabrikorganisation (FBO): *Produktentstehungsprozess, Auftragsabwicklung, Arbeitsvorbereitung* von Prof. Dr. Morlock (2024).

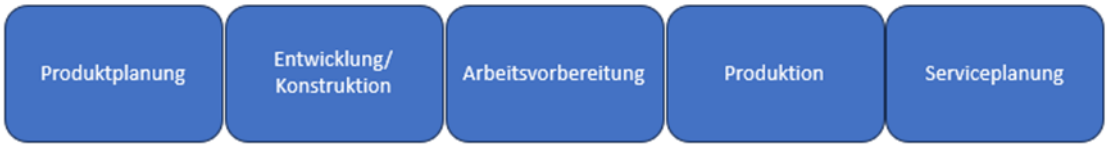


*Abbildung 2: Phasen des Produktentstehungsprozesses in Anlehnung an Prof. Dr. Morlock (2024)*

Vor diesem Hintergrund stellt sich die Frage, inwieweit generative KI in den einzelnen Phasen des Produktentstehungsprozesses als unterstützendes Werkzeug eingesetzt werden kann. Die Technologie eröffnet vielfältige Möglichkeiten, bestehende Abläufe zu ergänzen, effizienter zu

gestalten und qualitativ zu verbessern. Durch eine gezielte Zuordnung der Stärken generativer KI zu den jeweiligen Entwicklungsstufen lässt sich aufzeigen, welches Potenzial diese Technologie für die zukünftige Gestaltung ingenieurtechnischer Arbeitsweisen bietet.

### *4.1.1 Phase 1: Produktplanung*

Die erste Phase des Produktentstehungsprozesses bildet die strategische Vorphase, in der die Grundlagen für die nachfolgenden Entwicklungsaktivitäten gelegt werden. In diesem frühen Stadium werden Marktpotenziale, Kundenbedürfnisse und technologische Trends systematisch untersucht, um zukünftige Produktfelder und Innovationschancen zu identifizieren. Ziel ist die Definition des neuen Produkts aus der doppelten Perspektive von Markt und Technologie, wobei bestimmt wird, an welche Zielgruppe sich das Produkt richtet und welche Funktionen und Leistungsmerkmale es erfüllen soll. Auf dieser Basis erfolgt die Generierung, Bewertung und Auswahl vielversprechender Produktideen, die sowohl den strategischen Unternehmenszielen als auch den identifizierten Marktanforderungen entsprechen. Parallel dazu werden erste Produkt- und Designbeschreibungen erstellt, die eine grobe Positionierung des Produkts im Wettbewerbsumfeld ermöglichen. Diese Phase mündet in die Formulierung zentraler Produktanforderungen, welche den inhaltlichen und technologischen Rahmen für die anschließende Entwicklung definieren. Die Produktplanung übernimmt damit eine zentrale Rolle für die strategische und technologische Weichenstellung des gesamten Produktentstehungsprozesses. (Cantamessa & Montagna, 2023)

Hieraus lassen sich für diese Phase typische Aufgaben und Anwendungsfelder ableiten, zu denen Markt- und Trendanalyse, Wettbewerbs- und Kundenbedarfsanalysen, Ideenfindung und -bewertung sowie erste Konzeptdefinitionen und Wirtschaftlichkeitsabschätzungen zählen. In diesem Zusammenhang verweisen die folgenden Studien auf die vielfältigen Potenziale des Einsatzes generativer KI innerhalb dieser kreativen und strategischen Tätigkeiten. Sie verdeutlichen, wie der aktuelle wissenschaftliche Diskurs den Beitrag generativer KI zur Steigerung der Innovationsfähigkeit in der frühen Phase des Produktentstehungsprozesses beschreibt und aufzeigt, in welcher Weise diese Technologie die entsprechenden Aktivitäten gezielt unterstützen kann.

Eine Studie verdeutlicht das Anwendungspotenzial generativer KI in der Markt-, Trend- und Kundenbedarfsanalyse, insbesondere in der frühen Phase adressierten Aktivitäten des Produktentstehungsprozesses. Generative KI-Modelle, vor allem Large Language Models (LLMs) wie Chat GPT oder Bard, werden hier hervorgehoben. Ihr Einsatz ermöglicht einen Umgang

mit umfangreichen unstrukturierten Datenmengen aus Markt-, Kunden- und wettbewerbsquellen zu analysieren. Diese Fähigkeit, natürliche Sprache zu verarbeiten und kontextbezogenen Bedeutungen zu erkennen, können diese Modelle Muster, Trends und latente Bedürfnisse identifizieren, die in klassischen Analysemethoden oft verborgen bleiben. Es wird beschrieben, dass LLMs in der Lage sind, Marktreaktionen zu simulieren und so die Rolle hypothetischer Konsumenten einzunehmen. Sie unterstützen Unternehmen bei der Interpretation von Markt Trends, der Einschätzung von Produktpräferenzen und der Prognose potenzieller Nachfrageentwicklungen. Gleichzeitig werden sie eingesetzt, um aus großen Datenbeständen, etwa wie Social-Media-Inhalten, Kundenbewertungen oder offenen Textfeldern aus Umfragen, Erkenntnisse über Kundenmotive und Bedürfnisse zu generieren. Dadurch können Produktmanager: innen frühzeitig Chancenfelder identifizieren und strategische Entscheidungen datenbasiert untermauern. Darüber hinaus wird hervorgehoben, dass hinsichtlich der Nutzung von generativer KI die Modelle durch wiederholte Interaktionen und Rückkopplungsschleifen lernen, ihre Analysen kontinuierlich zu verfeinern. Dies ermöglicht eine zunehmende präzise Erfassung von Markt- und Kundeninformationen zu verdichten, um eine fundierte Grundlage für Produktkonzeption und -strategie zu schaffen. Damit wird generative KI zu einem entscheidenden Instrument der datengetriebenen Entscheidungsunterstützung im frühen Stadium des Produktentstehungsprozesses hervorgehoben. (Parikh, 2023)

Diese Erkenntnisse und Einsatzmöglichkeiten generativer KI aus der Studie sind theoretisch fundiert und beruhen auf literaturgestützten, konzeptionellen Ableitungen darüber, wie generative Modelle in diesen Anwendungsfeldern eingesetzt werden können. Eine ergänzende Umfrage zur Transformation der Marktforschung zeigt, dass 45% der befragten Unternehmen generative KI bereits aktiv in daten- und erkenntnisbasierten Prozessen nutzen, während weitere 45% den Einsatz in naher Zukunft planen. Damit wird deutlich, dass generative KI zunehmend ein integraler Bestandteil moderner Marktforschungspraktiken wird und maßgeblich dazu beiträgt, Kundenbedürfnisse zu verstehen, Wettbewerbsdynamik zu bewerten und datengestützte Entscheidungen organisatorisch zu erweitern. (Toubia, 2025)

Daraus lässt sich erkennen, dass dieses Anwendungsfeld, geprägt durch wissensintensive und qualitativ unstrukturierte Daten, ein besonders geeignetes Umfeld für den Einsatz generativer KI darstellt. Durch ihre Fähigkeit, große Mengen komplexer Marktdaten zu verarbeiten, Muster zu erkennen und Informationen zu verdichten, ermöglicht sie die zielgerichtete Generierung von Hypothesen für neue Produktideen sowie die automatisierte Aufbereitung von Anforderungsdokumenten. Generative KI trägt somit wesentlich dazu bei, den Erkenntnisgewinn in der

frühen Phase des Produktentstehungsprozesses zu beschleunigen und strategische Entscheidungen datenbasiert zu untermauern.

Für das Anwendungsfeld der Ideenfindung und Konzeptentwicklung lässt sich ebenfalls ein konzeptioneller Einsatz generativer KI verorten. Sie agiert dabei auf einer kollaborativen Ebene zwischen menschlicher Kreativität und maschineller Unterstützung. Eine Studie, die im Kontext von Design-Studierenden durchgeführt wurde, verdeutlicht den theoretischen und technologischen Mehrwert des Einsatzes, insbesondere im Hinblick auf die strukturierte und inspirierende Gestaltung früher Entwicklungsphasen. Das sogenannte *Designer-Generative AI Ideation Process Modell* erweitert den klassischen Planungsprozess um KI-basierte Unterstützungsmechanismen. Zum Einsatz kommen hierbei Modelle wie Chat GPT und Midjourney, die unterschiedliche, sich ergänzende Funktionen erfüllen. Während Chat GPT als analytisches Werkzeug fungiert, indem es Schlüsselbegriffe extrahiert, kontextualisiert und nach Relevanz gewichtet, dient Midjourney als bildgenerativ es System zur Visualisierung abstrakter Konzepte. Durch die Verbindung dieser textuellen und visuellen Komponenten entsteht ein interaktiver Ideationsprozess, der die Generierung, Bewertung und den Vergleich von Produktideen bereits in einem sehr frühen Stadium ermöglicht, noch bevor umfangreiche Entwicklungsressourcen gebunden werden müssen. (Kwon et. al., 2023)

Der zentrale Nutzen dieses Ansatzes liegt somit in der frühzeitigen Visualisierung und Reflexion von Produktideen, was zu einer höheren Effizienz, Strukturierung und kreativen Vielfalt in der Konzeptentwicklung führt. Auch wenn diese Erkenntnisse ursprünglich aus dem Designkontext stammen, lässt sich die beschriebene Herangehensweise auf die Design- und Entwicklungsaufgaben von Ingenieur: innen übertragen.

So zeigt es sich in einer anderen Studie, dass auch im technischen Kernbereich des Maschinenbaus der zunehmende Einsatz generativer Designsysteme, die auf modernen KI-Architekturen wie Variationalen Autoencodern (VAEs) und diffusionsbasierten Modellen beruhen, konzeptionell betrachtet werden kann. Solche Systeme wie etwa *Autodesk Generative Design, nTopology oder Siemens NX Generative Engineering* entfalten ihr Potenzial bereits in der Ideen- und Konzeptphase. Auf Basis definierter Randbedingungen wie Materialeigenschaften, Belastungsgrenzen oder Fertigungsvorgaben generieren, analysieren und bewerten sie eine Vielzahl von Varianten, noch bevor eine konkrete CAD-Umsetzung erfolgt. Damit verschiebt sich der klassische sequenzielle Ablauf hin zu einem iterativ-generativen Vorgehen, in dem Ingenieur: innen als Verantwortliche KI-Vorschläge auswählen, begründen und verfeinern. Parallel diskutiert die Studie den Einsatz großer Sprachmodelle (LLMs) wie Chat GPT, Claude oder Gemini als

integralen Bestandteil ingenieurwissenschaftlicher Tätigkeiten. Diese Modelle übernehmen die Analyse, Strukturierung und Automatisierung Informationsbezogener Prozesse. Im Maschinenbau umfasst dies u. a. die automatische Erstellung technischer Dokumentationen, Anforderungsanalysen, die Übersetzung von Spezifikationen sowie die Erklärung komplexer Simulationsabläufe in natürlicher Sprache. Darüber hinaus unterstützen LLMs die Generierung, Bewertung und Priorisierung von Konzeptideen auf Basis vorhandener CAD- und Projektdaten und fungieren damit als kommunikative Schnittstelle zwischen Menschen, System und Datenbasis, die technische Informationen kontextualisiert, zugänglich macht und den interdisziplinären Wissensaustausch fördert. Ergänzend verweist die Studie ebenfalls auch auf bild- und formgenerative Modelle wie *Stable Diffusion* und *DALL-E 3*, die vor allem in der Konzept- und Frühentwicklungsphase eingesetzt werden. Analog zu Midjourney ermöglichen sie die Visualisierung abstrakter Ideen und technischer Konzepte lange vor der CAD-Modellierung oder physischen Prototypen. Dadurch werden Varianten visuell vergleichbar, der Austausch zwischen Entwicklung, Marketing und Design erleichtert und Stakeholder-Feedback früh eingebunden. (Peckham et. al., 2025) Damit wird verdeutlich, dass ein zentraler Mehrwert in der Verschmelzung analytischer und kreativer Prozesse liegt, wodurch generative KI im Maschinenbau eine neue Qualität der Ideenfindung und Konzeptentwicklung ermöglicht. Während Sprachmodelle die Strukturierung von Wissen und Kontext übernehmen, übersetzen bild- und formgenerative Modelle diese in visuell erfassbare Konzepte, was zu einer Beschleunigung von Entscheidungsprozessen und einer deutlichen Steigerung der konzeptionellen Effizienz führen kann.

### *4.1.2 Phase 2: Entwicklung & Konstruktion*

Die zweite Phase des Produktentstehungsprozesses, Entwicklung und Konstruktion, bildet nach der Konzeptphase den Kern der technischen Produktentwicklung. Sie beginnt, sobald das Produktkonzept definiert ist, und zielt darauf ab, dieses Konzept in eine technische umsetzbare Lösung zu überführen. Im Mittelpunkt steht dabei die funktionalen und marktseitigen Anforderungen aus der ersten Phase in konkrete technische Spezifikationen und Gestaltungsmerkmalen zu übersetzen. Somit ist das Ergebnis der Entwicklungs- und Konstruktionsphase ein technisch validiertes Produktdesign, das eine vollständig beschriebene, funktionstüchtige Lösung darstellt. (Cantamessa & Montagna, 2023)

Der Übergang zwischen der marktorientierten Konzeptdefinition und der technisch-konstruktiven Entwicklungsphase vollzieht sich als ein Schrittweiser, methodisch strukturierter Prozess. Während in der ersten Phase die Marktanalyse, Identifikation von Kundenbedürfnissen und damit verbundene erste Ideenfindung und Konzeptdefinition im Mittelpunkt standen, dient diese

Phase primär einer strategischen Ausrichtung des Produktes. Sie bildet somit eine Schnittstelle zwischen den Marktanforderungen und der technischen Möglichkeiten. Ziel ist es, eine kohärente Verbindung zwischen den identifizierten Marktpotenzialen und den technologischen Voraussetzungen zu schaffen, um eine Grundlage für die in der zweiten Phase technischen Ideengenerierung zu legen. In der zweiten Phase des Produktentstehungsprozesses verschiebt sich somit der Fokus zunehmend auf eine Technische Perspektive. Auf Basis der zuvor definierten Anforderungen erfolgt nun die funktionale Beschreibung des Produktes, bei der alternative technische Lösungen generiert und systematisch bewertet werden. Dabei wird das zuvor abstrakte Produktkonzept sukzessiv in konkrete, technisch realisierbare Varianten überführt. (Cantamessa & Montagna, 2023)

Der Einsatz generativer KI ist somit nicht mehr ideenorientierte Planung, sondern konzentriert sich in dieser Phase vielmehr auf die technisch-kreative Ausgestaltungen des Produktes.

An dieser Stelle zwischen Kreativität und technischer Konkretisierung wird der Einsatz generativer KI untersucht. Traditionell wird in dieser Phase stark auf kreative Methoden wie das Brainstorming zurückgegriffen, das seit Jahrzehnten ein fester Bestandteil der Produktentwicklung ist. Brainstorming fördert in einem offenen, wertungsfreien Umfeld die Generierung zahlreicher unterschiedlicher Ideen und hat sich insbesondere im ingenieurtechnischen Kontext als wirksame Methode erwiesen, um vielfältige Konzepte für neue Funktionen oder Designelemente hervorzubringen. Im Vordergrund steht dabei weniger die unmittelbare Qualität, sondern vielmehr die Vielfalt und Quantität der Ideen, um in kurzer Zeit einen breiten Pool potenzieller Lösungsansätze zu schaffen. Mit dem Aufkommen generativer KI (*Artificial Generated Content, AIGC*) erweitert sich dieses Spektrum der Ideengenerierung. AIGC-gestützte Verfahren nutzen leistungsfähige Modelle wie DCGANs oder PGGANs, um automatisiert Bildmaterial und Gestaltungsideen zu erzeugen, die als visuelle Impulse für die Entwicklung dienen. Diese unterstützen Entwickler: innen nicht nur dabei, bekannte Muster effizient zu variieren, sondern auch völlig neuartige Ansätze sichtbar zu machen. Empirische Studien, etwa im automobilen Design (z.B. zur Gestaltung von Rückleuchten), zeigen, dass AIGC-basierte Bildvorschläge die kreative Vielfalt messbar erhöhen und als Inspirationsquelle über klassische Brainstorming-Sitzungen hinauswirken. Der Nutzen hängt dabei maßgeblich von der Qualität der generierten Inhalte ab. Hochwertige, detailreiche Visualisierungen fördern die Weiterentwicklung und Konkretisierung von Ideen, während unscharfe oder mehrdeutige Darstellungen zwar eine hohe Vielfalt anregen, zugleich aber erhöhte Interpretationsleistungen erfordern. Generative KI er-

setzt somit nicht die klassische Konzeptarbeit, sondern erweitert sie um datengetriebene kreative Prozesse. Während das Brainstorming den menschlichen Austausch, die Intuition und das assoziative Denken stärkt, können generative KI-Systeme in kürzester Zeit eine Vielzahl visueller Entwürfe erzeugen, die als Grundlage für Diskussionen und Entscheidungen dienen. Übertragbar auf den Kontext im Maschinenbau eröffnet dies die Möglichkeit, bereits in der frühen Entwicklungsphase Variantenräume systematisch zu erweitern und damit die Basis für innovative Produktlösungen zu schaffen. (Lin et. al., 2024)

In den frühen Phasen der Produktentwicklung, besonders in der Entwurfs- und Konstruktionsphase werden dabei neben den klassischen Kreativitätstechniken wie dem Brainstorming zunehmend auch systematische Methoden eingesetzt, die eine analytische Problemlösung ermöglichen. Eine der bekanntesten ist die Theorie des erfinderischen Problemlösens (TRIZ), deren Ziel es ist, wiederkehrende Muster technischer Innovationen zu identifizieren und daraus allgemeine Prinzipien zur Auflösung technischer Widersprüche abzuleiten. Grundlage bilden hierbei eine Widerspruchsmatrix und Innovationsprinzipien, mit denen sich Zielkonflikte methodisch strukturieren und überwinden lassen. Trotz ihres hohen methodischen Anspruchs ist TRIZ in der industriellen Praxis aufgrund ihres Aufwands und der erforderlichen Expertise oft schwer anwendbar. Mit dem Aufkommen generativer KI eröffnen sich hier neue Ansätze zur Automatisierung und Effizienzsteigerung. Ein aktuelles Beispiel ist das entwickelte System AutoTRIZ, das den gesamten TRIZ-Prozess mithilfe von Large Language Models (LLMs) automatisiert. Das System verarbeitet natürlichsprachliche Problembeschreibungen, identifiziert widersprüchliche technische Anforderungen, leitet passende Innovationsprinzipien ab und generiert daraus strukturierte Lösungsvorschläge. Anhand eines praxisnahen Fallbeispiels aus der Entwicklung eines Batterie-Thermomanagementsystems (BTMS) konnte AutoTRIZ zeigen, dass sich auf dieser Grundlage technische realisierbare und innovative Konzepte entwickeln lassen. Das System schlug bspw. den Einsatz flacher, mehrkammeriger Wärmerohre vor, die ein deutliche Verbesserung der thermischen Effizienz bewirkten. Diese Ergebnisse verdeutlichen, dass TRIZ durch generative KI nicht ersetzt, sondern intelligent erweitert wird, womit der systematische Lösungsraum in der frühen Entwicklungsphase Ingenieur: innen dabei unterstützt, analytische und kreative Elemente der Problemlösung miteinander zu verbinden. (Jiang et. al., 2025) Während AIGC-gestützte Verfahren und das System AutoTRIZ den Einsatz generativer KI vor allem in den frühen Phasen der Entwicklung verdeutlichen und dort kreative wie analy-

tische Prozesse wirkungsvoll unterstützen, verschiebt sich der Schwerpunkt im weiteren Verlauf der zweiten Phase Entwicklung und Konstruktion zunehmend von der ideenorientierten hin zur technischen Konkretisierung und digitalen Modellbildung.

In dieser Phase, die die eigentliche Konstruktion und die Erstellung erster Prototypen umfasst, treten neue Herausforderungen bei der Anwendung generativer KI auf. Besonders deutlich wird dies im Zusammenhang mit dem Training und der Leistungsfähigkeit generativer KI-Modelle, die maßgeblich von der Verfügbarkeit hochwertiger und repräsentativer CAD-Daten abhängen, einem Bereich, in dem der aktuelle Entwicklungsstand noch unzureichend ist. Zwar stehen verschiedene öffentliche CAD-Datensätze zur Verfügung, diese weisen jedoch signifikante Einschränkungen auf. Der ABC-Datensatz umfasst zwar eine große Anzahl an 3D-Modellen, enthält jedoch keine Konstruktionshistorien, was eine Nachverfolgung des Entstehungsprozesses ausschließt. Sketch Graphs bietet umfangreiche 2D-Zeichnungen mit Zwangsbedingungen, ist jedoch auf die Skizzenebe beschränkt und daher nur bedingt für komplexe Konstruktionsaufgaben geeignet. Deep CAD beinhaltet Modelle mit einfachen Konstruktionshistorien, beschränkt sich jedoch auf grundlegende Operationen und bildet die Komplexität industrieller CAD-Modelle nur eingeschränkt ab. Die Fusion 360 Gallery wiederum stellt vollständige Konstruktionshistorien bereit, umfasst jedoch überwiegend kleine und wenig komplexe Geometrien. Diese Defizite an qualitativ hochwertigen, industriell repräsentativen Datensätzen stellt eine der zentralen Implementierungsbarrieren für den Einsatz generativer KI in CAD-Prozessen dar. (Berger et. al., 2025)

Gleichzeitig zeigen aktuelle Entwicklungen, dass sich dieser Engpass durch neue methodische Ansätze zunehmend überwinden lässt. Generative KI eröffnet in Verbindung mit CAD-Automatisierung neue Möglichkeiten, auch bei eingeschränkter Datenlage tragfähige und vielfältige Komponentendesigns zu entwickeln. Während herkömmliche CAD-Verfahren auf umfangreiche Datenbestände und regelbasierten Modellierungen angewiesen sind, können generative Modelle bereits aus kleinen und heterogenen Datensätzen funktionsfähige Lösungen erzeugen. Ein besonders vielversprechender Ansatz besteht im Einsatz von *Low-Rank Adaptation* (LoRA), durch den sich der Trainingsbedarf erheblich reduzieren lässt. In einer exemplarischen Anwendung konnte die Zahl der erforderlichen Trainingsbeispiele von rund 16.000 auf etwa 200 reduziert werden, ohne dass die Ergebnisqualität signifikant beeinträchtigt wurde. Hierbei wurde ein vortrainiertes Stable-Diffusion-Modell mithilfe von LoRA gezielt auf das Felgendesign angepasst. Trotz der stark reduzierten Datenbasis war das Modell in der Lage, aus einfa-

chen Texteingaben eine Vielzahl funktionaler und strukturell valider CAD-Designs zu generieren, von denen rund 90% die geometrische und strukturelle Validierung bestanden. Darüber hinaus zeigte sich eine deutliche Reduktion der Entwicklungszeit. Die Generierung eines Designs erfolgte innerhalb von Sekunden, und erste Rückmeldungen zweier Industriepartner bestätigten eine Verkürzung der Konzept- bis Prototypenphase um etwa 30%. Diese Ergebnisse verdeutlichen das Potenzial generativer KI, die Effizienz technischer Entwicklungsprozesse signifikant zu steigern und neue Wege in der CAD-basierten Konstruktion zu eröffnen. (Li et. al., 2025)

Darüber hinaus zeigt sich, dass generative KI auch neue Formen der Interaktion in CAD-Umgebungen ermöglicht. Mit dem benutzerfreundlichen, in Python entwickelten GAD-Framework (*Generative-AI-assisted Design*) wurde eine Plattform geschaffen, die multimodale Eingaben in Form von Text, Bild und Sprache integriert. Dadurch können CAD-Modelle selbst dann generiert werden, wenn Spezifikationen unvollständig oder nur teilweise vorhanden sind. Dieser Ansatz bietet insbesondere in frühen Entwicklungsphasen eine erhebliche Arbeitserleichterung, da Ingenieur: innen bereits auf Basis grober oder unvollständiger Vorgaben erste funktionsfähige Modellvarianten erzeugen können, ohne dass sämtliche Konstruktionsparameter vorab präzise definiert sein müssen. Gleichzeitig zeigen sich technologische Grenzen bei komplexen Geometrien, wobei die Maßhaltigkeit bislang nur teilweise gewährleistet wird, da die Modelle feine Dimensionen und Details nicht immer exakt rekonstruieren können. Insgesamt verdeutlicht aber dieser Ansatz, dass generative KI neue, interaktive Gestaltungsformen in CAD-Systemen ermöglicht, zugleich aber technische Restriktionen bestehen, die bei der Modellierung anspruchsvoller Geometrien berücksichtigt werden müssen. (Daareyni et. al., 2025)

In einem weiteren Beispiel zeigt sich, dass auch in CAD-Umgebungen gängige generative KI-Werkzeuge als interaktive Komponente eingesetzt werden können. In einer experimentellen Untersuchung wurden Chat GPT und Google Gemini Advanced mit den CAD-Programmen Fusion 360 und Inventor Professional kombiniert, um deren Leistungsfähigkeit im konstruktiven Entwicklungsprozess zu erproben. Ziel war es zu untersuchen, inwieweit diese Sprachmodelle nicht nur einfache Konstruktionsaufgaben unterstützen, sondern auch komplexere Designprozesse in CAD-Umgebungen initiieren und begleiten können. Die Ergebnisse zeigen, dass beide Systeme in der Lage waren, konstruktive Aufgabenstellungen zu interpretieren, arithmetische Berechnungen durchzuführen und schrittweise Anweisungen für CAD-Operationen zu generieren. Zwar traten wiederholt fehlerhafte Instruktionen auf, diese konnten jedoch nach gezielten Nachprompts größtenteils eigenständig korrigiert werden. Bemerkenswert ist, dass

die Modelle nicht nur vorgegebene Aufgaben lösten, sondern auch selbstständig kreative Geometrievarianten entwickelten, etwa Verzahnungen, spiralförmige Durchbrüche oder alternative Formkonzepte. Im weiteren Verlauf erwiesen sich beide Systeme als fähig, eigenständige Produktentwürfe, wie im experimentellen Beispiel der Konstruktion eines Kopfhörerständers, vollständig auszuarbeiten. Trotz identischer Aufgabenstellung entstanden dabei mehrere unterschiedliche, sowohl funktional als auch gestalterisch überzeugende Designvarianten. Diese Ergebnisse verdeutlichen, dass generative KI-Modelle bereits heute als interaktive Komponenten in CAD-Umgebungen fungieren und neue Impulse für den Konstruktionsprozess liefern können. Sie erweitern die Möglichkeiten in der Phase der Entwicklung und Konstruktion, indem sie Routineaufgaben automatisieren und gleichzeitig die Variantenvielfalt sowie die konzeptionelle Breite in frühen Entwicklungsphasen erhöhen. (Byrne et. al., 2025)

Aus der Literaturanalyse lässt sich demnach ableiten, dass der Einsatz generativer KI in der Phase der Entwicklung und Konstruktion potenziell zu einer Steigerung von Effizienz, Flexibilität und kreativer Vielfalt führen kann. Es wird deutlich, dass Ingenieur: innen durch KI-Systeme dabei unterstützt werden könnten, technische Lösungen schneller zu entwickeln, eine größere Variantenvielfalt zu erzeugen und somit unterschiedliche Entwurfsoptionen gezielt zu bewerten. Ebenso kann generative KI zur technischen Ausgestaltung konstruktiver Lösungen beitragen, indem sie die Überführung von Ideen in umsetzbare Modelle erleichtert, geometrische Abhängigkeiten analysiert und Routine- sowie Berechnungsaufgaben automatisiert. Insgesamt deutet die Literatur darauf hin, dass der Einsatz generativer KI den methodischen Gestaltungsspielraum in dieser Phase erweitern und eine engere Verbindung zwischen kreativen und analytischen Prozessen fördern könnte, was langfristig zu verkürzten Innovationszyklen und qualitativ verbesserten Entwicklungsentscheidungen führen kann.

### *4.1.3 Phase 3: Arbeitsvorbereitung*

Die dritte Phase des Produktentstehungsprozesses, die Arbeitsvorbereitung, schließt unmittelbar an die Entwicklungs- und Konstruktionsphase an und bildet die Brücke zwischen technischer Produktentwicklung und industrieller Fertigung. Ihr Ziel besteht darin, das validierte Produktdesign in fertigungsfähige und reproduzierbare Produktionsprozesse zu überführen. Im Mittelpunkt steht die detaillierte Planung aller technischen und organisatorischen Abläufe, die eine effiziente und qualitätsgesicherte Herstellung des Produkts ermöglichen. (Cantamessa & Montagna, 2023)

Die Arbeitsvorbereitung fungiert als Schnittstelle zwischen der Entwicklung und Konstruktion auf der einen Seite so wie der tatsächlichen Produktion auf der anderen.

Mit dem Framework CAPP-GPT (*Computer-Aided Process Planning – Generative Pretrained Transformer)* liegt ein Ansatz vor, der generative KI-Modelle gezielt in die rechnerunterstützte Arbeitsplanung integriert. Dabei werden sowohl Aufgaben der Makro-CAPP-Ebene, etwa Setup-Planung, Sequenzierung von Bearbeitungsschritten und Gruppierung von Fertigungsmerkmalen, als auch Aspekte der Mikro-CAPP-Ebene, wie die Auswahl optimaler Prozessparameter und die Generierung effizienter Werkzeugwege, adressiert. Der Einsatz generativer KI wird hierbei insbesondere durch die Kombination mit Digital-Twin-Technologie, Maschinelles Lernen und Optimierungsalgorithmen gestärkt. Diese Integration ermöglicht es, Produktionsstörungen auf dem Shopfloor frühzeitig zu erkennen und durch selbstadaptierende Steuerungsmechanismen automatische geeignete Anpassungen vorzunehmen. Damit wandelt sich die Arbeitsvorbereitung von einer überwiegend planenden zu einer proaktiv steuernden Instanz, die in der Lage ist, dynamische Veränderungen in Echtzeiten zu kompensieren. Pilotanwendung innerhalb des Frameworks verdeutlichen dieses Potenzial anhand der Planung komplexer Variantenfamilien, bei denen additive und subtraktive Fertigungsschritte kombiniert werden. Dabei zeigt sich, dass durch die Einbindungen von KI-basierten Planungsverfahren eine gleichzeitige Optimierung von Materialeinsatz, Bearbeitungszeit, Energieverbrauch, Emissionen und Qualitätsparametern erreicht werden kann. Auf diese Weise trägt CAPP-GPT nicht nur zur Steigerung der Effizienz und Flexibilität bei, sondern eröffnet zugleich neue Perspektiven für nachhaltige und ressourcenschonende Produktionsgestaltung. (Azab et. al., 2024)

Im Rahmen der Literaturrecherche ergab sich eine weitere Erkenntnis, die den Einsatz generativer KI in der Arbeitsvorbereitung aus einer konzeptionellen Perspektive beschreibt. Das auf theoretischer Forschung basierende Referenzframework sowie die darin dargestellten simulativen Demonstrationsbeispiele verdeutlichen praxisnah, wie generative KI genutzt werden kann, um Effizienz und Flexibilität in der Produktionsplanung zu steigern. Ein zentraler Anwendungsfall ist die sogenannte *Factory Layout Generation,* bei der auf Grundlage definierter Raumgrenzen und Flächenanforderungen automatisiert eine Vielzahl möglicher Fabriklayouts generiert und in weiteren Schritten verfeinert werden kann. Dadurch entfällt ein erheblicher Teil manueller Variantenarbeit, während gleichzeitig neuartige und optimierte Anordnungen von Maschinen und Arbeitsplätzen entstehen. Ein weiterer relevanter Anwendungsfall ist die *Production Concept Generation,* die insbesondere für flexible und matrixstrukturierte Fertigungssysteme entwickelt wurde. Hier werden probabilistische Modellierungen und agentenbasierte Simulationen eingesetzt, um Szenarien unter Unsicherheit zu analysieren und deren Auswirkungen auf Effizienz und Durchsatz zu bewerten. Methoden wie Monte-Carlo-Simulationen

und Clustering-Verfahren ermöglichen dabei die Identifikation relevanter Szenarien und die Ableitung robuster, anpassungsfähiger Produktionskonzepte. Darüber hinaus zeigt die *Synthetic Data Generation for Vision Technology*, wie generative KI zur Qualitätssicherung beitragen kann. Mithilfe digitaler Zwillinge werden synthetische Bilddaten erzeugt, die für das Training von *Convolutional Neural Networks* genutzt werden, Objekterkennungen und Fehlerreduktion in realen Produktionsumgebungen zu verbessern. Diese Vorgehensweise ermöglicht eine präzisere und effizientere Qualitätskontrolle, ohne dass aufwendige oder kostenintensive reale Datensammlungen erforderlich sind. Insgesamt wird deutlich, dass generative KI in der Arbeitsvorbereitung nicht nur den Planungsaufwand reduziert, sondern auch eine Grundlage für adaptive und lernfähige Produktionssysteme schafft, die Qualität, Effizienz und Flexibilität gleichermaßen fördern. (Filz et. al., 2024)

Ein weiterer Einsatz generativer KI zeigt sich in dieser Phase in der Programmierung und Steuerung von Fertigungsprozessen, wo sie zur Automatisierung und Effizienzsteigerung beiträgt. Ein zentraler Ansatz ist hierbei die Nutzung von Large Language Modes (LLMs) zur automatischen Generierung von G-Code aus natürlichsprachlichen Anweisungen. Mit dem entwickelten Framework GLLM ist es möglich, komplexe Bearbeitungsaufgaben für CNC-Maschinen direkt aus textlichen Beschreibungen abzuleiten. Dadurch entfällt die zeitaufwendige und fehleranfällige manuelle Programmierung, die bislang tiefgehendes Fachwissen über Maschinentechnik, Werkzeugbewegungen und Bearbeitungsparametern erforderte. Diese Entwicklung trägt zur Demokratisierung der CNC-Programmierung bei, da sie auch Anwender: innen ohne spezialisierte Programmierkenntnisse den Zugang zu komplexen Fertigungsaufgaben erleichtert und das Fachpersonal entlastet. Technisch basiert der Ansatz auf der Kombination feinjustierter Large Language Models, einer Retrieval-Augmented-Generation-Architektur und einem selbstkorrigierenden Codegenerationsmechanismus. Das System extrahiert aus der textlichen Beschreibung zentrale Parameter wie Werkstückmaße, Schnitttiefe oder Werkezugwege, überprüft diese automatisch und überführt sie einen in ausführbaren G-Code. Eine zentrale Rolle spielt dabei die iterative Selbstkorrektur. Generierte Programme werden auf syntaktische und semantische Konsistenz getestet, wobei erkannte Abweichungen in Form von Feedbackschleifen automatisch korrigiert werden. Auf diese Weise entsteht ein verlässlicher Code, der sowohl formal korrekt als auch funktional präzise ausgeführt werden kann. Ergänzend erfolgt eine visuelle Simulation der Werkzeugbewegung, die eine zusätzliche Validierung des generierten Codes ermöglicht. Die experimentellen Ergebnisse zeigen, dass insbesondere strukturierte

Prompts die Erfolgsrate der Codegenerierung signifikant erhöhen und nahezu fehlerfreie Ergebnisse ermöglichen. Unstrukturierte Eingaben führten hingegen zu größeren Schwankungen in der Genauigkeit, während klar formulierte Parameter Erfolgsraten von bis zu 100% erreichten. Zudem zeigte sich, dass die Komplexität der Bearbeitungsaufgaben einen direkten Einfluss auf die Leistungsfähigkeit der Modelle hat. Bei einfachen Geometrien, wie Kreise oder Quadern, konnte der Code in wenigen Iterationen erfolgreich generiert werden, wohingegen komplexere Strukturen, beispielsweise Taschen mit mehreren Inseln, deutlich mehr Korrekturschleifen erforderten. Diese Befunde verdeutlichen die Bedeutung von gezieltem Prompt Engineering als Schlüsselkompetenz für den praktischen Einsatz generativer KI in der Arbeitsvorbereitung. (Abdelaal et. al., 2025)

Die Auswertung der herangezogenen Literatur verdeutlicht, dass der Einsatz generativer KI das Potenzial besitzt, die Arbeitsvorbereitung grundlegend zu verändern. Sie übernimmt nicht nur planerische Routineaufgaben, sondern ermöglicht eine automatisierte, adaptive und datengetriebene Gestaltung von Fertigungsprozessen. Damit wird die Arbeitsvorbereitung zu einer aktiven, selbstlernenden Instanz, die Effizienz, Flexibilität und Qualität in der Produktion entscheidend steigert.

### *4.1.4 Phase 4: Produktion*

Die vierte Phase des Produktentstehungsprozesses, die Produktion, markiert den Übergang von der Planung zur praktischen Umsetzung. In dieser Phase werden die in der Arbeitsvorbereitung definierten Prozesse und Ressourcen in die industrielle Realität überführt. Ziel ist die Herstellung des Produktes unter stabilen, wirtschaftlichen und qualitätsgesicherten Bedingungen. Die Produktionsphase umfasst dabei sämtliche Aktivitäten des Produktionsanlaufs, der Serienfertigung und der laufenden Qualitätskontrolle. Dabei steht die Reproduzierbarkeit der Produktqualität im Vordergrund, um sicherzustellen, dass jedes gefertigte Produkt den technischen Spezifikationen entspricht. Neben der technischen Umsetzung spielen in dieser Phase auch Aspekte der Prozessoptimierung und kontinuierlichen Verbesserung eine zentrale Rolle. Rückmeldungen aus der Fertigung werden systematisch erfasst, um Produktionsabläufe, Materialflüsse und Ressourceneinsatz zu optimieren. Damit ist die Produktionsphase nicht nur die operative Realisierung der Produktentstehung, sondern zugleich ein wesentlicher Bestandteil des Lern- und Verbesserungsprozesses innerhalb des Produktentstehungsprozesses. (Cantamessa & Montagna, 2023)

Ein zentrales Anwendungsfeld generativer KI in der Phase der Produktion liegt in der Qualitätssicherung. Hier lässt sich vor allem der Einsatz im Bereich der Defekterkennung untersuchen. Dabei liegt der Fokus auf der Nutzung generativer Modelle wie Generative Adversarial Networks (GANs) und Variational Autoencoders (VAEs), die gezielt eingesetzt werden, um die Qualitätssicherung in realen Fertigungsprozessen zu verbessern. Im Gegensatz zu klassischen Defekterkennungsmethoden, die auf manueller Inspektion oder starren regelbasierten Algorithmen beruhen und dadurch zeitaufwendig sowie fehleranfällig sind, bietet generativer KI einen datengetriebenen und lernfähigen Ansatz, der sowohl die Erkennung als auch die Prävention von Fehlern deutlich effizienter gestaltet. Ein zentrales Problem herkömmlicher Systeme besteht jedoch in der begrenzten Verfügbarkeit und Ungleichverteilung von Trainingsdaten. Da fehlerhafte Produkte in der Produktionsumgebung häufig wenige repräsentative Beispiele zur Verfügung stellen können für das Training klassischer Deep-Learning-Modelle. Hier setzt der generative Ansatz jedoch an. Mithilfe von GANs lassen sich synthetische Bilddaten erzeugen, die reale Produktionsbedingungen wie Beleuchtung, Oberflächenstruktur oder Defektformen imitieren. Diese künstlich generierten Bilder werden anschließend genutzt, um die Trainingsdatensätze für maschinelle Lernmodelle zu erweitern und zu differenzieren. Dadurch wird die Datenknappheit kompensiert, was die Lernfähigkeit und Generalisierungsleistung der Defekterkennungsmodelle erheblich verbessert. Besonders hervorzuheben ist, dass der Einsatz generativer Modelle nicht direkte Fehlererkennung übernimmt, sondern die zugrundeliegenden Systeme durch gezielte Datenaugmentation leistungsfähiger macht. Studien, die im Rahmen dieser Literatur ausgewertet wurden, zeigen, dass der Einsatz von GANs in der Defekterkennung die Erkennungsgenauigkeit um 20-30% steigern und die Entwicklungszyklen um bis zu 15% verkürzen kann. VAEs werden ergänzend eingesetzt, um robuste Repräsentationen visueller Merkmale zu lernen und damit die Stabilität der Klassifikation bei komplexen oder verrauschten Datensätzen zu erhöhen. Generative KI unterstützt an dieser Stelle nicht nur die Defekterkennung, sondern trägt gleichzeitig auch dazu bei Entwicklungszeiten zu verkürzen, die Produktqualität zu verbessern und Ausschuss sowie den Ressourcenverbrauch zu reduzieren. Damit wird sie zu einem zentralen Instrument der datengestützten, selbstoptimierenden Fertigung und stärkt den Übergang hin zu einer intelligenten Produktionsumgebung. (Shafiee, 2024)

In der Produktionsphase zeigt sich anhand dieser Studie der Einsatz generativer KI in einer neuen Qualität, die über klassische Ansätze der Defekterkennung hinausgeht. Während herkömmliche Qualitätssicherungssysteme in der Regel auf der nachträglichen Erkennung von

Produktfehlern basieren, wird nun ein generatives KI-Modell eingesetzt, um Produktionsprozesse in Echtzeit zu überwachen, zu simulieren und aktiv zu steuern. Die theoretische-konzeptionell erarbeitete Grundlage dieses Ansatzes wurde in einer praxisnahem Pilotanwendung empirisch validiert und verdeutlicht die Umsetzbarkeit generativer KI in realen Fertigungsumgebungen. Ziel ist dabei nicht mehr die nachträgliche Erkennung von Abweichungen, sondern deren frühzeitige Vermeidung durch adaptive Eingriffe in laufende Fertigungsprozesse. Die in diesem Zusammenhang eingesetzten generativen Modelle, sind Generative Adversarial Networks (GANs), Variational Autoencoders (VAEs) und Transformer-basierte-Architekturen, die die komplementären Funktionen in der Prozessteuerung übernehmen. GANs werden genutzt, um synthetische Prozessdaten zu erzeugen und damit Lücken oder Ungleichgewichte in realen Sensordaten auszugleichen. VAEs modellieren komplexe Zusammenhänge zwischen zentralen Prozessparametern wie Schichtdicke, Vorschub, Energieeintrag oder Temperatur und ermöglichen dadurch die Vorhersage potenzieller Abweichungen. Transformer-Modelle dienen der kontinuierlichen Analyse von Sensordatenströmen und passen Prozessparameter in Echtzeit an, wodurch Abweichungen unmittelbar korrigiert werden können. Besonders deutlich wird das Potenzial dieses Ansatzes im industriellen Anwendungsfall der additiven Fertigung mit Laser-Pulverbettverfahren (LPBF). In diesem Szenario wurde das Framework auf ein reales LPBF-System angewendet, um Parameter wie Laserleistung, Schichtdicke und Scanstrategie adaptiv zu steuern. Die generativen Modelle nutzten hierbei sowohl simulierte als auch reale Sensordaten, um Prozessabweichungen frühzeitig zu identifizieren und automatisch zu kompensieren. Die Ergebnisse zeigten eine signifikante Steigerung der Bauteilqualität um rund 18% sowie eine Reduktion des Materialverbrauchs um etwa 12%. Gleichzeitig konnte die Prozessstabilität erhöht und der Energieeinsatz optimiert werden. (Kausik et. al., 2025)

Neben der Effizienzsteigerung durch die Reduktion von Produktfehlern spielt auch die frühzeitige Erkennung von Maschinenfehlern eine zentrale Rolle für die Leistungsfähigkeit industrieller Fertigungssysteme. Auch hier kommen die Modell GANs und VAEs zum Einsatz, um auf Grundlage von Sensordaten Abweichungen im Maschinenverhalten zu identifizieren, bevor es zu einem Ausfall kommt. Durch den kontinuierlichen Vergleich realer Messdaten mit synthetisch generierten Referenzmuster können Anomalien während des laufenden Produktionsprozesses erkannt und vorbeugende Wartungsmaßnahmen eingeleitet werden. Auf diese Weise lässt sich die Anlagenverfügbarkeit erhöhen, unvorhergesehene Stillstände werden vermieden, und die Gesamtanlageneffizienz kann nachhaltig gesteigert werden. (Shafiee, 2024)

### *4.1.5 Phase 5: Serviceplanung*

Die fünfte Phase des Produktentstehungsprozesses, die Serviceplanung, folgt auf die Auslieferung und Nutzung des Produktes beim Kunden. Ihr Ziel ist die langfristige Sicherstellung der Funktionsfähigkeit, Zuverlässigkeit und Kundenzufriedenheit über den gesamten Lebenszyklus hinweg. Diese Phase beinhaltet die Planung und Organisation aller Dienstleistungen, die nach der Produktion erforderlich sind, darunter die Wartung, Instandhaltung, Ersatzteilmanagement, Schulung des Servicepersonals sowie die Definition von Prozessen für Rückmeldungen aus dem Feld. Sie stellt sicher, dass technische und organisatorische Voraussetzungen für einen effizienten After-Sales-Betrieb geschaffen werden. Darüber hinaus liefert sie wertvolle Informationen für zukünftige Entwicklungsprozesse, indem Erfahrungen aus der Produktnutzung systematisch in die Weiterentwicklung und Verbesserung nachfolgender Produktgenerationen zurückgeführt werden können. (Cantamessa & Montagna, 2023)

Vor allem zeigt sich auch hier in der Literaturrecherche ein Interessantes Anwendungsfeld für den Einsatz generativer KI-Modelle in den Bereichen Wartung und Instandhaltung. Klassische Ansätze der Instandhaltung, etwa reaktive Wartung nach Störfällen oder präventive, zeitgesteuerte Wartung, sind häufig mit hohen Stillstandzeiten oder unnötigen Wartungskosten verbunden. Auch hier ermöglichen die Generative KI-Modelle GANs und VAEs eine datengetriebene und zustandsbasierte Wartungsplanung. (Mohapatra, 2024) Ähnlich wie bereits in der Phase der Produktion vorgestellt kamen diese KI-Modelle zum Einsatz, um im laufenden Produktionsprozess Abweichungen im Maschinenverhalten zu identifizieren, bevor es zu einem Ausfall kommt (Shafiee, 2024). Hier unterscheidet es sich in der Ausrichtung des Fokus, während die Produktion auf Qualitätskontrolle, Prozesssicherheit und Effizienz in der Produktion abzielt, richtet sich die Serviceplanung auf die langfristige Sicherstellung der Betriebsfähigkeit und Wartungsstrategien der eingesetzten Maschinen und Anlagen beim Kunden. Der Unterschied für den Einsatz generativer KI liegt somit im zeitlichen und funktionalen Kontext.

Neben dem ähnlichen Einsatz der generativen Modelle zur synthetischen Erzeugung von Maschinendaten, um Störungen realistisch zu simulieren, und schließlich KI-Systemen eine Trainingsgrundlage darzubieten, auf der die Vorhersagegenauigkeit verbessert wird. Wird im Kontext dieser Phase eine Erweiterung durchgeführt durch die Integration von Digital Twins, die als virtuelle Abbilder physischer Maschinen fungieren. Diese werden kontinuierlich mit Echtzeitdaten gespeist und durch generative Simulationen erweitert, sodass sich der Zustand von Anlagen permanent überwachen und mögliche Ausfallverläufe vorausschauend simulieren lassen. Wartungsfenster können dadurch gezielt in Phasen niedriger Auslastung gelegt werden,

was Produktionsunterbrechungen minimiert und die Betriebseffizienz steigert. Die Studie aus der Literatur belegt den Nutzen dieses Ansatzes deutlich. Durch die Kombination von generativer KI und digitalen Zwillingen lassen sich Wartungskosten um 10-20% senken und Stillstandzeiten um 30-40% reduzieren. Damit trägt generative KI wesentlich zur Effizienzsteigerung, zur Ressourcenschonung und zu einer nachhaltigen Sicherung der Produktionskontinuität bei. Sie markiert den Übergang von reaktiven zu selbstlernenden, adaptiven Servicekonzepten, die ein zentrales Element intelligenter Produktionssysteme darstellen. (Mohapatra, 2024)

### *4.1.6 Systematische Einordnung des Einsatzes generativer KI im PEP*

Aufbauend auf den Ergebnissen der vorangegangenen Literaturrecherche systematisiert die nachfolgende Darstellung den Einsatz generativer Künstlicher Intelligenz entlang der zentralen Phasen des Produktentstehungsprozesses. Ziel ist es, ein umfassendes Bild der bisherigen Forschungs- und Anwendungslage zu zeichnen, indem aufgezeigt wird, in welchen Prozessabschnitten generative KI-Modelle einen erkennbaren Mehrwert leisten können. Dabei werden sowohl theoretisch-konzeptionelle Ansätze als auch empirisch untersuchte, praxisnahe Anwendungen berücksichtigt, die bereits in Pilotprojekten erprobt wurden. Die anschließende tabellarische Übersicht fasst die identifizierten Anwendungsfelder zusammen und verdeutlich, welche funktionalen Schwerpunkte sich innerhalb der einzelnen PEP-Phasen herausgebildet haben.

*Tabelle 1: Systematische Einordnung funktionaler Anwendungsfelder entlang des Produktentstehungsprozesses*

| | |
|---|---|
| **Phase 1:** Produktplanung | Analyse von Markt-, Kunden-, und Wettbewerbsdaten durch Large Language Models (LLMs), um Trends, Muster und Latente Bedürfnisse zu erkennen. Sowie generative Unterstützung der Ideenfindung und Konzeptentwicklung. |
| **Phase 2:** Entwicklung und Konstruktion | KI-gestützte Variantenbildung und Konzeptgenerierung in CAD-Systemen sowie KI-gestützte Konstruktionsgenerierung in CAD-Umgebungen |
| **Phase 3:** Arbeitsvorbereitung | KI-gestützte Prozess- und Arbeitsplanung in der Fertigungsvorbereitung. |
| **Phase 4:** Produktion | KI-gestützte Qualitäts- und Prozessüberwachung in der Produktion (Defekt- und Anomalie Erkennung der Produkte, und Prozessüberwachung). |
| **Phase 5:** Serviceplanung | KI-gestützte zustandsbasierte Wartungs- und Serviceplanung. |

Wie sich schließlich in der Tabelle 1 verdeutlicht, zeigt sich der Einsatz generativer entlang des gesamten Produktentstehungsprozesses, von der datenbasierten Markt- und Konzeptanalyse in der Produktplanung über die automatisierte Varianten- und Konstruktionsgenerierung in der Entwicklung bis hin zu KI-gestützten Prozessplanung, Qualitätsüberwachung und der vorausschauenden Wartung in Produktion und Serviceplanung.
Die derzeit identifizierten Anwendungen generativer Künstlicher Intelligenz im Produktentstehungsprozess basieren überwiegend auf einem klar abgegrenzten Pool etablierter Modellarchitekturen, deren jeweilige Stärke sich in unterschiedlichen Einsatzkontexten zeigen. Hierbei zeigen sich folgende Modelltypen aus dem Kontext der Literaturrecherche wieder.

*Tabelle 2: Eingesetzte generative KI-Werkzeuge aus der Literaturrecherche*

| |
|---|
| **Transformermodelle:** *Chat GPT* |
| **Multimodale Transformermodelle:** *Midjourney, Bard* |
| **Generative Adversarial Networks** *(GANs)* und **Variational Autoencoders** *(VAEs)* |
| **Diffusionsmodelle** |

Transformermodelle, insbesondere in Form von Large Language Models (LLMs), stellen derzeit die dominierende Technologie dar. Sie werden vorrangig in textbasierten Aufgaben eingesetzt, etwa zur Analyse von Markt- und Kundendaten, zur Generierung von Konzeptideen oder zur Unterstützung in der Projekt- und Prozessplanung. Ihre Fähigkeit, kontextabhängige Informationen zu verarbeiten und neue Inhalte in natürlicher Sprache zu erzeugen, macht sie zu einem zentralen Werkzeug in der frühen Produktplanung sowie in wissensintensiven Phasen der Entwicklung und Arbeitsvorbereitung. Neben den klassischen textbasierten Large Language Models haben sich auch multimodale Transformermodelle hervorgehoben die Bild-, Text- und teilweise auch 3D-Daten verarbeiten und generieren können. Diese Entwicklung erweitert den verfügbaren Pool generativer KI-Werkzeuge im Produktentstehungsprozess. Sie ermöglichen die schnelle visuelle Umsetzung und Gegenüberstellung von Konzeptideen, wodurch insbesondere die frühen Phasen der Produktplanung und -entwicklung unterstützt werden. Durch die Möglichkeit, textuelle Anforderungen unmittelbar in bildhafte Darstellungen zu übersetzen, können alternative Designvarianten visualisiert, Entscheidungsprozesse beschleunigt und interdisziplinäre Abstimmungen erleichtert werden. Die Ergebnisse der Literaturrecherche verdeutlichen, dass insbesondere in den frühen Phasen der Produktentwicklung schließlich generative

KI-Werkzeuge wie LLMs und Bildgenerierungsmodelle einen entscheidenden Mehrwert bieten. Modelle wie Chat GPT werden eingesetzt, um Markttrends, Nutzungskontexte und technologische Optionen zu analysieren sowie Ideen strukturiert zu formulieren und weiterzuentwickeln. Ergänzend ermöglichen Bildmodelle wie Midjourney oder DALL-E die schnelle visuelle Umsetzung und Gegenüberstellung von Konzeptideen, wodurch kreative Entscheidungsprozesse daten- und bildgestützt werden. Diese Verbindung von sprach- und bildbasierter Generierung fördert eine neue Form der explorativen Produktplanung, in der algorithmische Unterstützung und menschliche Kreativität ineinandergreifen. Damit wird der Ideenraum in der frühen Entwicklung deutlich erweitert, und der Übergang von der konzeptionellen zur technischen Phase effizienter gestaltet. (Kwon et. al., 2024; Lin et. al., 2025) GANs und VAEs kommen dagegen in der Qualitätssicherung der Produktionsphase zum Einsatz. Sie dienen der Defekterkennung und Prozessüberwachung und leisten hier einen entscheidenden Beitrag in der synthetischen Bild- und Sensordatengenerierung, die reale Datensätze ergänzen und so die Datenknappheit in Produktionsumgebungen kompensieren. (Shafiee, 2024; Kausik et. al., 2025) Diese generativen KI-Modelle können in ihrer Modellarchitektur auch anderweitig eingesetzt werden. Wie die folgende Studie darlegt, zählen GANs und VAEs zu den zentralen Architekturen, die insbesondere in der technischen Produktentwicklung Anwendung finden. Beide Modelle tragen zur Automatisierung von Entwicklungsaufgaben und zur Unterstützung der CAD-Modellgenerierung bei. Der besondere Nutzen liegt dabei in der Beschleunigung von Entwicklungsprozessen und der Erweiterung des kreativen Lösungsraums, wobei der Bedarf an umfangreichen Trainingsdaten als zentrale Herausforderung gilt. (Berger, 2024)

## 4.2 MTO-Modell

Das MTO-Modell stellt ein anerkanntes Konzept zur Analyse und Gestaltung soziotechnischer Systeme dar. Es integriert die Dimensionen Mensch, Technik und Organisation in einem systemischen Zusammenhang und verdeutlicht, dass technologische Innovationen nicht isoliert betrachtet werden können. Vielmehr sind sie stets im Wechselspiel individueller Kompetenzen und Einstellungen, der eingesetzten technischen Systeme sowie der organisatorischen Strukturen und Prozesse zu verstehen. Jede dieser Dimensionen leistet einen wesentlichen Beitrag zum erfolgreichen und verantwortungsvollen Einsatz neuer Technologien im industriellen Kontext. Die Einführung generativer KI erfordert daher nicht nur die Entwicklung entsprechender technischer Infrastrukturen, sondern auch die Förderung von Kompetenzen und Akzeptanz auf Seiten der Beschäftigten sowie die Schaffung geeigneter organisatorischer Rahmenbedingungen.

Das MTO-Modell ist zwar darauf ausgerichtet, die Wechselwirkungen zwischen den Dimensionen Mensch, Technik und Organisation in ihrer gegenseitigen Abhängigkeit zu analysieren, wird im Kontext des Einsatzes generativer KI im Maschinenbau jedoch differenziert betrachtet. Diese methodische Vorgehensweise stellt keinen Widerspruch zum ursprünglichen Konzept dar, sondern ermöglicht eine vertiefte Analyse der einzelnen Dimensionen in ihrer jeweiligen Eigenständigkeit. Eine solche Differenzierung bietet wertvolle Erkenntnisse darüber, wie generative KI in technische, personelle und organisatorische Strukturen eingebettet werden kann. Zugleich schafft sie die Grundlage, generative KI nicht ausschließlich als technologische, sondern als soziotechnische Innovation zu verstehen, deren erfolgreicher Einsatz maßgeblich von einer ausgewogenen Balance zwischen Mensch, Technik und Organisation abhängt. (Bendel & Latniak, 2023; Ulich, 2013)

Vor diesem Hintergrund bietet das MTO-Modell eine geeignete theoretische Grundlage, um die in der Literatur gewonnen Erkenntnisse zum Einsatz generativer KI systematisch einzuordnen. Es ermöglicht, die Potenziale und Herausforderungen dieser Technologie differenziert zu analysieren und die Wechselwirkungen zwischen Menschen, Technik und Organisation sichtbar zu machen. Auf diese Weise lässt sich erkennen, an welchen Schnittstellen generative KI in bestehende Strukturen integriert werden, kann und welche organisatorischen, technischen und personalbezogenen Voraussetzungen für eine erfolgreiche Implementierung erforderlich sind.

### *4.2.1 Dimension Mensch*

Die Dimension Mensch im MTO-Modell umfasst die in Arbeitssystemen handelnden Personen mit ihren Kompetenzen, Bedürfnissen und Gestaltungsmöglichkeiten. Der Mensch wird dabei als aktives, selbstregulierendes Element verstanden, das die Schnittstelle zwischen technischen Systemen und organisationalen Strukturen bildet. Seine Qualifikationen, Handlungsspielräume und Entscheidungsfreiheiten bestimmen maßgeblich die Qualität der Interaktion im soziotechnischen Gesamtsystem und sind zentrale Voraussetzungen für eine gemeinsame Optimierung von Mensch, Technik, und Organisation. (Ulich, 2013)

Wie bereits in der explorativen Vorstudie untersucht wurde, war eine zentrale Fragestellung, wie Ingenieur: innen den Einsatz generativer KI im Arbeitskontext wahrnehmen und in welchem Maße sie darin ein mögliches Substitut menschlicher Arbeit sehen. Die Ergebnisse zeigten deutlich, dass generative KI derzeit nicht als Ersatz, sondern vielmehr als ergänzendes Werkzeug verstanden wird, das die fachliche Expertise und kreative Leistungsfähigkeit von Ingenieur: innen erweitert. Der Mensch bleibt dabei die zentrale Instanz, die über die Qualität,

Angemessenheit und ethische Vertretbarkeit der durch KI erzeugten Ergebnisse entscheidet. (Morlock et. al., 2025; Berger et. al., 2025) Diese Sichtweise entspricht dem Verständnis der Dimension Mensch im MTO-Modell, in der der Mensch als selbstregulierende, kompetenzbasiertes und verantwortungsbewusstes Element des soziotechnischen Systems beschrieben wird. (Ulich, 2013) Ein weiterer zentraler Aspekt innerhalb der Dimension Mensch betrifft demnach die Kompetenz und Erfahrungen der Anwender: innen im Umgang mit generativer KI. (Ulich, 2013) Wie sich aus der Literaturrecherche zeigt, hängt die Qualität der erzielten Ergebnisse maßgeblich von der Fähigkeit der Nutzenden ab, Prompts gezielt und präzise zu formulieren. Unterschiedliche Techniken, etwa additive, narrative oder kategoriespezifische Prompts, führen zu variierenden Resultaten und verdeutlichen, dass die Effektivität der Nutzung stark vom Erfahrungs- und Wissensstand der Anwender: innen abhängt. (Kwon et. al., 2025). Personen mit höherer Expertise erzielen konsistent relevantere und verlässlichere Ergebnisse, da sie in der Lage sind, iterative Prompt-Strategien bewusster einzusetzen, Abfragen präziser zu gestalten und die Logik der KI-Ausgaben kritisch zu bewerten. (Jiang et. al., 2025; Byrne et. al., 2025) Diese Befunde lassen sich im Sinne der Dimension Mensch interpretieren. Der Mensch wird hier nicht nur als aktives, lern- und anpassungsfähiges System verstanden, das technische Prozesse nicht nur ausführt, sondern reguliert, reflektiert und gestaltet. Individuelle Kompetenz, Erfahrung und kognitive Fähigkeiten bestimmen demnach, in welchem Umfang generative KI wirksam und verantwortungsvoll genutzt werden kann. Zugleich zeigt sich, dass die Qualität dieser Interaktion nicht allein von der Person abhängt, sondern auch von technischen und organisationalen Rahmenbedingungen beeinflusst wird. (Ulich, 2013)

In diesem Kontext stellt das von Davies (1986) entwickelte Technologieakzeptanzmodell (TAM) einen zentralen theoretischen Ansatz dar, der die individuelle Haltung und Akzeptanz gegenüber neuen Technologien thematisiert. Dabei wird die subjektive Einstellung einer Person gegenüber einer Technologie wesentlich durch zwei kognitive Faktoren bestimmt. Die wahrgenommene Nützlichkeit und die wahrgenommene Benutzerfreundlichkeit. Diese Wahrnehmungen beeinflussen die Einstellungsakzeptanz, also die positive oder negative Bewertung der Technologie durch die Nutzer: innen. Die Einstellungsakzeptanz beschreibt somit die subjektive Haltung einer Person und bildet die psychologische Brücke zwischen Wahrnehmung und Verhalten. Sie bestimmt, ob eine Person bereit ist, eine Technologie tatsächlich zu nutzen. Aus dieser positiven oder negativen Haltung resultiert schließlich die Verhaltensakzeptanz, also die tatsächliche Nutzung oder Ablehnung der Technologie im Arbeitskontext. Damit wird verdeutlicht, dass technologische Implementierung nicht allein durch funktionale Leistungsfähigkeit

bestimmt werden, sondern wesentlich von der individuellen Wahrnehmung und Bewertung der Technologie abhängen. (Bandow & Holzmüller, 2009) Die Dimension Mensch umfasst dabei alle psychischen, wahrnehmungsbezogenen und antriebsbezogenen Aspekte menschlichen Handelns im Arbeitssystem und betont die Bedeutung subjektiver Wahrnehmung und Bewertung im Umgang mit Technik. Die Einstellungsakzeptanz im Sinne des TAM-Modells repräsentiert somit die subjektive Haltung des Menschen gegenüber der Technik, während die daraus hervorgehende Verhaltensakzeptanz den Grad der Integration der Technologie in das tatsächliche Arbeitsverhalten widerspiegelt. In der Systematik des MTO-Modells stellt diese Haltung die entscheidende Bindung zwischen dem sozialen Teilsystem (Mensch) und dem technischen Teilsystem (Technik) dar. Sie bestimmen, wie gut die technische Gestaltung und die organisatorischen Rahmenbedingungen mit den psychologischen Voraussetzungen und Bedürfnissen der Beschäftigten übereinstimmt. (Bendal & Holzmüller, 2009; Ulich, 2013)

Darüber hinaus wird in der Literatur die Bedeutung demografischer Faktoren für die Interaktion mit generativer Modelle hervorgehoben. In einer Studie wird verwiesen, dass männliche und weibliche Designer: innen unterschiedliche Strategien bei der Nutzung KI-gestützter Methoden anwenden. Während männliche Teilnehmende bei visuellen Reizen niedriger Qualität tendenziell eine größere Anzahl an Ideen entwickelten, erzielten weibliche Teilnehmende bei qualitativ hochwertigen Bildern überlegene Ergebnisse. Die Qualität der visuellen Anreize beeinflusste somit das kreative Potenzial der Nutzer: innen auf unterschiedliche Weise. Auch dies lässt sich der Dimension Mensch zuordnen, da er individuelle Unterschiede in Wahrnehmung, Informationsverarbeitung und kreativer Leistungsfähigkeit widerspiegelt. Zugleich wird deutlich, dass demografische Merkmale wie das Geschlecht die Wirksamkeit und Nutzungsgüte technischer Systeme mitbestimmen können. (Lin et. al., 2024; Ulich, 2013)

Die Akzeptanz und effektive Nutzung neuer Technologien entstehen somit nicht allein aus individuellen Faktoren, sondern im Wechselspiel mit den technischen Möglichkeiten und organisationalen Rahmenbedingungen, wodurch die menschliche Rolle zunehmend von der Ausführung hin zur Überwachung, Bewertung und Gestaltung technischer Prozesse verschoben wird. (Ulich, 2013)

### *4.2.2 Dimension Technik*

Die Dimension Technik im MTO-Modell umfasst sämtliche technischen und infrastrukturellen Elemente eines Arbeitssystems, die Arbeitsprozesse unterstützen, strukturieren und prägen. Technik wird dabei nicht als isolierte Komponente verstanden, sondern als integraler Bestandteil eines soziotechnischen Gesamtsystems, das in enger Wechselwirkung mit menschlichen

Handlungen und organisationalen Strukturen steht. Im Kontext generativer KI gewinnt die technische Dimension besonders Bedeutung, da die Leistungsfähigkeit dieser Systeme maßgeblich von der Qualität der zugrunde liegenden Daten, der Systemarchitektur und der Integration in bestehende digitale Entwicklungsumgebungen abhängt. Die Art der technischen Implementierung bestimmt dabei nicht nur die Funktionalität, sondern auch die Nutzbarkeit und Akzeptanz der Systeme. (Ulich, 2013)

Im Kontext des Technologieakzeptanzmodells lässt auch im Teilsystem der Technik dieses wieder aufnehmen. Das TAM stellt die wahrgenommene Bedienbarkeit als eine der zentralen kognitiven Einflussfaktoren dar, die das individuelle Akzeptanzverhalten gegenüber technologischen Systemen prägen. Sie beschreibt das Ausmaß, in dem eine Person erwartet, ein technisches System ohne großen Aufwand bedienen zu können. Diese Erwartung betrifft nicht allein die physische oder ergonomische Handhabung, sondern auch die kognitive Verständlichkeit und den intuitiven Zugang zur Funktionalität der Technologie. Im theoretischen Gefüge des TAM beeinflusst die wahrgenommene Bedienbarkeit sowohl direkt als auch indirekt die Verhaltensakzeptanz und somit die tatsächliche Nutzung der Technologie. (Bandow & Holzmüller, 2009) Überträgt man diese theoretische Perspektive in das MTO-Modell lässt sich die wahrgenommene Bedienbarkeit der Dimension Technik zuordnen. Den diese Dimension umfasst alle technischen, materiellen und funktionalen Elemente des Arbeitssystems, einschließlich der Gestaltung von Benutzeroberflächen und Interaktionslogiken. Während im TAM die wahrgenommene Bedienbarkeit eine psychologische Variable darstellt, verweist sie im MTO-Kontext auf die technische Gestaltungseigenschaft, die die Wahrnehmung hervorruft. Ein Benutzerfreundliches technisches Design, das auf Verständlichkeit, Transparenz und Fehlerrobustheit ausgelegt ist, schafft die Voraussetzung für eine positive Wahrnehmung der Bedienbarkeit und trägt damit zur Akzeptanz und erfolgreichen Nutzung der Technologie bei. (Bandow & Holzmüller, 2009; Ulich, 2013)

Ein anschauliches Beispiel für die Dimension Technik zeigt sich in der Literatur ebenfalls in der Integration generativer KI in CAD-basierten Entwicklungs- und Produktionsprozesse. Hierbei wird hervorgehoben, dass noch erhebliche technische Herausforderungen bestehen, die sich vor allem auf begrenzte Datenverfügbarkeit, fehlende Schnittstellenfähigkeit und eingeschränkten Funktionsumfang zurückführen lassen. Insbesondere herstellerspezifische CAD-Formate und unvollständige Datensätze behindern den Zugriff auf Konstruktionshistorien und Informationen, wodurch die Leistungsfähigkeit generativer Modelle eingeschränkt wird. Im Sinne der

technischen Dimension des MTO-Modells verdeutlicht dieser Befund, dass der Reifegrad generativer KI-Systeme nicht allein von algorithmischen Fortschritten abhängt, sondern wesentlich von der Offenheit und Strukturierung der zugrunde liegenden technischen Systeme beeinflusst wird. Technik ist damit kein statischer Rahmen, sondern ein gestaltbarer Entwicklungsfaktor dessen Weiterentwicklung über reine Automatisierung hinausgehen muss, um menschliche Kreativität und Ingenieurkompetenz gezielt zu unterstützen. (Berger et. al., 2025)

### *4.2.3 Dimension Organisation*

Die Dimension Organisation umfasst die Strukturen, Prozesse und Regelwerke, die die Zusammenarbeit, Koordination und Aufgabenverteilung innerhalb eines Arbeitssystems bestimmen. Sie bildet den Rahmen, in dem Mensch und Technik interagieren, und wird als dynamisches Teilsystem verstanden, das sich kontinuierlich an technologische und soziale Veränderungen anpasst. (Ulich, 2013)

Im Zuge der digitalen Transformation, insbesondere durch den Einsatz generativer Künstlicher Intelligenz im Ingenieurwesen, erhält die Organisation eine zentrale Rolle bei der Gestaltung des Zusammenspiels von Mensch und Technik. Die Unternehmensgröße wirkt dabei als wichtiger Indikator für die organisatorische Leistungsfähigkeit. Sie zeigt, in welchem Maß ein Unternehmen in der Lage ist, neue Technologien aufzunehmen, in bestehende Strukturen einzubinden und produktiv zu nutzen. Die Unternehmensgröße beeinflusst entscheidend die organisationalen Anpassungs- und Leistungsprozesse. Große Unternehmen verfügen über standardisierte Strukturen und klare Entscheidungswege, was ihre Effizienz stärkt, jedoch ihre Flexibilität einschränkt. Dadurch reagieren sie langsamer auf technologische Neuerungen wie generative KI und zeigen eine geringere Adoptionsgeschwindigkeit. (Sommer, 2015)

Kleinere und mittlere Unternehmen besitzen dagegen flachere Strukturen und höhere Agilität. Dies ermöglicht es ihnen, neue Technologien schneller zu erproben und kreativ zu nutzen, auch wenn begrenzte Ressourcen ihre Umsetzungskapazität einschränken. (Sommer, 2015)

Unternehmen verfügen jedoch auch trotz geringerer Beweglichkeit über eine ausgeprägte strukturelle Integrationsfähigkeit. Sie können Wissen systematisch aufnehmen und in Prozesse einbetten, sobald eine Entscheidung zur Einführung getroffen wurde. Kleine und mittlere Unternehmen besitzen hingegen vor allem eine potenzielle Aufnahmekapazität, die auf ihre frühe Exploration, nicht aber auf nachhaltige Implementierung ausgerichtet ist. (Müller, 2021)

Im Kontext des Ingenieurwesens und der Nutzung generativer KI bedeutet dies, dass die organisationalen Voraussetzungen ein Indikator für erfolgreiche Implementierung darstellen kön-

nen, maßgeblich von der Größe und Struktur des Unternehmens abhängig. Große Ingenieurunternehmen können demnach generative KI in bestehende Entwicklungs- und Konstruktionsprozesse einbetten, durch algorithmische Unterstützung oder durch Simulationen. Kleinere und mittlere Unternehmen nutzen generative KI häufiger zur Entlastung kognitiver Routinetätigkeiten oder für kreative Entwurfsunterstützung, da ihre organisatorische Struktur eine experimentellere Einführung neuer Technologien erlaubt.

Ein weiterer Aspekt der Dimension Organisation ist der Schulungsbedarf. Mit der Einführung neuer Technologien wie generativer KI entstehen veränderte Kompetenzanforderungen, die sowohl technisches Wissen als auch organisatorisches Verständnis betreffen. Die Organisation ist ein dynamisches System, das sich nur dann erfolgreich an technologische Veränderungen anpassen kann, wenn die Qualifikationen der Mitarbeitenden gezielt mitentwickelt werden. Schulungen dienen dabei nicht nur der Wissensvermittlung, sondern auch der Integration neuer Technologien in bestehende Arbeitsprozesse und der Förderung einer gemeinsamen Aufgabenorientierung. (Ulich, 2013) Im Kontext generativer KI bedeutet dies, dass Schulungsmaßnahmen die Schnittstelle zwischen Mensch und Technik adressieren. Beschäftigte benötigen sowohl technische Anwendungskompetenz als auch ein Verständnis für organisatorische Abläufe und Entscheidungsstrukturen, um die Technologie sinnvoll einsetzen zu können. (Ulich, 2013)

# 5 Forschungsmodell

Die Ergebnisse der Literaturrecherche in Kapitel 4 zeigen, dass im Maschinenbau bereits eine Vielzahl konzeptioneller Ansätze sowie erste praxisnahe Anwendungen generativer KI existieren. Gleichwohl fehlt bislang eine systematische empirische Erfassung des tatsächlichen Einsatzes und der Vergleichbarkeit dieser Technologie im industriellen Alltag von Ingenieur: innen. Während theoretische Arbeiten vielfältige Potenziale und Einsatzmöglichkeiten entlang des Produktentstehungsprozesses aufzeigen und das MTO-Modell die Bedeutung organisationaler Strukturen sowie individueller Kompetenzen betont, bleibt bislang offen, in welchem Umfang diese Konzepte bereits in der beruflichen Praxis von Ingenieur: innen umgesetzt und aufgenommen werden. Vor diesem Hintergrund wird im Folgenden ein Forschungsmodell entwickelt, das die in der Literatur identifizierten Konzepte, Potenziale und Anwendungsfelder in einen strukturierten Bezugsrahmen überführt. Ziel des Modells ist es, die zentralen Einflussgrößen darunter den Wissensstand, die wahrgenommenen Potenziale und Risiken sowie den

tatsächlichen Nutzen des Einsatzes generativer KI in ihrer wechselseitigen Beziehung darzustellen. Das Modell verdichtet damit den theoretischen Forschungsstand und bildet zugleich die Grundlage für die empirische Untersuchung.

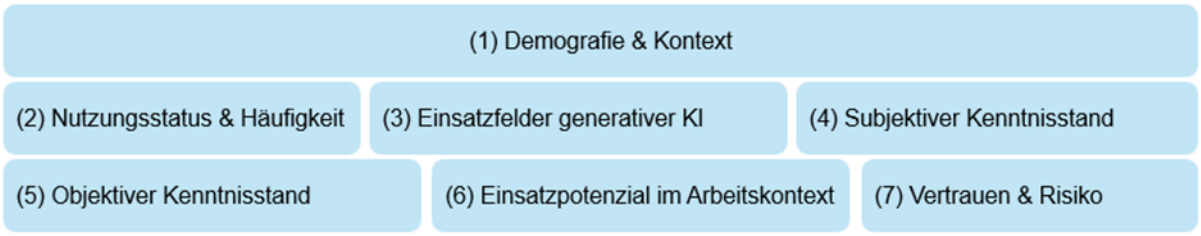


*Abbildung 3: Themenfelder des Forschungsmodells*

Wie in Abbildung 3 zu sehen, zeigt das Forschungsmodell die theoretischen Erkenntnisse in übergeordneten Themenfeldern, die in einen strukturierten Bezugsrahmen überführt und als Grundlage für die anschließende empirische Untersuchung dienen. Das Themenfeld (1) Demografie & Kontext bildet hierbei den Ausgangspunkt des Modells. Neben dieser grundlegenden Verortung individueller Merkmale ermöglicht das Themenfeld (2) Nutzungsstatus & Häufigkeit eine klare Unterscheidung zwischen Nutzer: innen und Nicht-Nutzer: innen generativer KI. Dadurch lassen sich tatsächliche Anwendungserfahrungen von hypothetischen Einschätzungen analytisch trennen und der Stand des Technologieeinsatzes differenziert erfassen. Darüber hinaus berücksichtigt das Modell das Themenfeld (3) Einsatzfelder generativer KI im Maschinenbau, welches die in der Literaturrecherche identifizierten Anwendungsbereiche aufgreift. Ein weiterer zentraler Bestandteil ist der Kenntnisstand, der im Modell zweigeteilt erfasst wird, einerseits als (4) Subjektiver Kenntnisstand durch eine Selbsteinschätzung, andererseits als (5) Objektiver Kenntnisstand in Form messbaren Wissens. Ergänzend werden das wahrgenommene (6) Einsatzpotenzial im Arbeitskontext sowie Aspekte des (7) Vertrauens & Risikos einbezogen, die für die Akzeptanz und Nutzung generativer KI eine zentrale Rolle spielen. Das Forschungsmodell verdichtet diese Themenfelder zu einem integrativen Rahmen und ermöglicht dadurch eine systematische empirische Untersuchung der relevanten Einflussgrößen des KI-Einsatzes im Maschinenbau. Die Untersuchung erfolgt anhand von Realitätsaufnahmen aus dem beruflichen Alltag von Ingenieur: innen. Auf dieser Grundlage erfolgt in den anschließenden Unterkapitel die konkrete Ableitung der Hypothesen.

## 5.1 Hypothesenentwicklung und -Herleitung

Auf Grundlage der theoretischen Erkenntnisse und des aktuellen Forschungsstands zur Nutzung generativer KI im industriellen Kontext werden im Folgenden die Hypothesen für die empirische Untersuchung entwickelt. Ziel der Hypothesenentwicklung ist es, zentrale Annahmen über den gegenwärtigen Stand, den tatsächlichen Einsatz und das wahrgenommene Potenzial generativer KI im Maschinenbau systematisch zu überprüfen. Die Hypothesen werden deduktiv aus der bestehenden Literatur abgeleitet und bilden die konzeptionelle Verbindung zwischen dem theoretischen Bezugsrahmen und der empirischen Datenerhebung. Sie strukturieren die Untersuchung, indem sie die in der Forschung identifizierten Zusammenhänge aus dem theoretischen Modell in empirisch überprüfbare Aussagen überführen.

### *5.1.1 Nutzungshäufigkeit und subjektiver Kenntnisstand*

Die Einbeziehung der Nutzungshäufigkeit als Themenfeld im Forschungsmodell lässt sich unmittelbar aus den Erkenntnissen des aktuellen Forschungsstands ableiten. Bereits in der strategischen Produktplanungsphase wird darauf hingewiesen, dass die Wirksamkeit generativer KI-Anwendungen maßgeblich von der Kompetenz der Anwender: innen abhängt. Nur durch präzise und zielgerichtete Prompts kann das kreative Potenzial der Modelle vollständig ausgeschöpft werden. (Kwon et. al., 2024) Empirische Befunde zeigen zudem, dass die tatsächliche Nutzung generativer KI nicht allein durch technologische Leistungsfähigkeit bestimmt wird, sondern wesentlich von der Fähigkeit und Erfahrung der Nutzenden abhängt. Auch in der Entwicklung- und Konstruktionsphase zeigt sich, dass wiederholte fehlerhafte Instruktionen durch gezieltes Nachprompten weitegehend korrigiert werden können. (Byrne et. al., 2025) Diese Ergebnisse verdeutlichen, dass die Nutzung generativer KI selbst einen iterativen Lernprozess darstellt, in dem sich Kompetenz schrittweise durch praktische Anwendung aufbaut. Die Häufigkeit der Nutzung kann somit als Indikator für den individuellen Erfahrungsgrad im Umgang mit der Technologie interpretiert werden.

Das Technologieakzeptanzmodell wurde durch das TAM3-Modell weiterentwickelt, in dem neben den ursprünglichen Einflussfaktoren des wahrgenommenen Nutzens und der wahrgenommenen Benutzerfreundlichkeit auch psychologische Determinanten berücksichtigt werden. Im TAM3 wurde das Modell um wahrnehmungsbezogene Einflussgrößen erweitert, die gezielt die Akzeptanz und Nutzung digitaler Technologien erklären. In diesem Zusammenhang wurde das Konzept digitaler Computer *Self-Efficacy* eingeführt, dass die individuelle Überzeugung beschreibt, digitale Technologien effektiv nutzen zu können. Diese Selbstwirksamkeitserwar-

tung spiegelt die subjektive Wahrnehmung der eigenen Kompetenz im Umgang mit Technologie wider und prägt maßgeblich die wahrgenommene Bedienbarkeit sowie die Bereitschaft zur Nutzung. Aus diesem theoretischen Ansatz leitet sich das Themenfeld des subjektiven Kenntnisstandes ab, das den individuellen Glauben an die eigene Fähigkeit zur Anwendung generativer KI beschreibt und somit eine zentrale psychologische Einflussgröße für das Nutzungsverhalten darstellt. (Bandow & Holzmüller, 2009)

In der Zusammenschau der theoretischen und empirischen Befunde zeigt sich, dass sowohl die Nutzungshäufigkeit als Ausdruck praktischer Erfahrung als auch der subjektive Kenntnisstand als Maß wahrgenommener Kompetenz zentrale Einflussgrößen darstellen, die in einem wechselseitigen Verhältnis zueinanderstehen. Wiederholte Nutzung generativer KI fördert den Aufbau von Anwendungskompetenz, während ein höherer subjektiver Kenntnisstand wiederum die Nutzungsintensität begünstigt. Auf dieser Grundlage wird die Hypothese formuliert, dass Ingenieur: innen mit einem höheren subjektiven Kenntnisstand generative KI häufiger in ihren Arbeitsprozess einsetzen.

### *5.1.2 Objektiver Kenntnisstand und Vertrauen*

Während das Themenfeld des subjektiven Kenntnisstandes und die damit impliziere Wahrnehmung beschreiben, wie kompetent sich eine Person in der Anwendung generativer KI einschätzt, rückt an dieser Stelle der objektive Kenntnisstand in den Fokus. Er bezieht sich auf das tatsächliche vorhandene Fachwissen, das die Grundlage für eine sachgerechte und effiziente Nutzung technologischer Systeme bildet. Bereits im ursprüngliche Technologieakzeptanzmodell wird Wissen als externe Einflussgröße verstanden, die die Wahrnehmung der Benutzerfreundlichkeit einer Technologie prägt. Personen mit höherem technischem Verständnis empfinden den Umgang mit neuen Technologien weniger komplex, was ihre Nutzungsbereitschaft fördert. Auch im erweiterten TAM2 zeigt sich, dass die Qualität der Systemnutzung und die wahrgenommene Ergebnisnachweisbarkeit eng mit dem vorhandenen Fachwissen der Anwender: innen verknüpft sind. Der objektive Kenntnisstand lässt sich somit als kognitive Grundlage dieser Wahrnehmungsprozesse interpretieren und ergänzt den subjektiv wahrgenommenen Kenntnisstand im Sinne des TAM3 um eine faktische Dimension technologischer Kompetenz. (Bandow & Holzmüller, 2009)

Ein fundiertes Verständnis der Funktionsprinzipien, Datenstrukturen und Prompt-Logiken generativer Modelle ist entscheidend, um deren Potenzial zielgerichtet ausschöpfen zu können. (Kwon et. al., 2024) Diese Relevanz zeigt sich insbesondere in der ingenieurtechnischen Praxis,

etwa beim Einsatz generativer KI-Tools in CAD-Umgebungen oder automatisierten Konstruktionsprozesses. Hier erfordert die Sicherstellung qualitativ hochwertiger Ergebnisse ein technisches Verständnis über Modellgrenzen, Datenqualität und Parametrierung. (Byrne et. al., 2025) Daraus lässt sich ableiten, dass der objektive Kenntnisstand eine zentrale kognitive Voraussetzung für den erfolgreichen und sicheren Einsatz generativer KI im industriellen Kontext darstellt.

Darüber hinaus spielt der objektive Kenntnisstand eine wesentliche Rolle für das Vertrauen in die Ergebnisse generativer KI. Ein höheres, auf Wissen basierendes Verständnis ermöglicht eine realistische Einschätzung der Zuverlässigkeit und Genauigkeit KI-generierter Resultate und lässt schließlich annehmen, dass sie eine Begründung für das Vertrauen in der Nutzung der Technologie fördert. Wissen reduziert Unsicherheit, stärkt die Fähigkeit zur kritischen Bewertung und unterstützt einen reflektierten Umgang mit maschinell erzeugten Informationen. Hierbei wird hervorgehoben das Vertrauen in KI-Systemen auf kognitive Prozesse beruhen, die auf Verständnis und Wissen über deren Funktionsweise und Grenzen aufbauen. Nur wenn Nutzer: innen die Mechanismen und Limitationen eines Systems nachvollziehen können, entsteht ein sogenanntes Warranted Trust, also ein gerechtfertigtes und sachlich fundiertes Vertrauen in die Technologie. In der ingenieurtechnischen Praxis, die durch Präzision und Nachvollziehbarkeit geprägt ist, wird Vertrauen in KI-Systeme somit maßgeblich durch das Niveau des objektiven Wissens bestimmt. (Jacovi et. al., 2021)

Auf Grundlage dieser theoretischen und empirischen Befunde wird folgende Hypothese formuliert. Ingenieur: innen mit einem höheren objektiv gemessenen Kenntnisstand weisen ein stärkeres Vertrauen in die Ergebnisse generativer KI auf.

### *5.1.3 Vertrauen als vermittelnde variabel*

Aufbauend auf den zuvor hergeleiteten Hypothesen und den theoretischen Grundlagen der Technologieakzeptanz- und Vertrauensforschung wird im Folgenden ein eigenständiges theoretischen Wirkungsmodell entwickelt. Es integriert die bisherigen Erkenntnisse zu Wissen, Vertrauen und Nutzung generativer KI und verdichtet sie zu einem übergeordneten Annahmegefüge. Ziel ist es, die vermuteten wechselseitigen Beziehungen zwischen objektivem und subjektivem Kenntnisstand, Vertrauen und Nutzungshäufigkeit abzuleiten.

Die Ergebnisse aus den theoretischen Grundlagen, die in den vorherigen Hypothesenentwicklungen und -Herleitungen eingebracht wurden, lassen einen kausalen Zusammenhang zwischen Wissen, Vertrauen und Nutzung generativer KI im ingenieurtechnischen Arbeitsumfeld hin-

deuten. Ausgangspunkt dieses Wirkgefüges ist der objektive Kenntnisstand, der das tatsächliche vorhandene überprüfbare Wissen über Funktionsprinzipien, Datenstrukturen und Einsatzgrenzen generativer KI beschreibt. Ein höheres objektives Wissen ermöglicht Ingenieur: innen, die Leistungsfähigkeit und Zuverlässigkeit der Systeme realistisch einzuschätzen und daraus ein fundiertes Verständnis ihres Anwendungspotenzials zu entwickeln, also die individuell wahrgenommene Kompetenz im Umgang mit der Technologie. Der subjektive Kenntnisstand beeinflusst wiederum das Vertrauen in die Ergebnisse generativer KI maßgeblich. Personen, die sich im Umgang mit der Technologie kompetent fühlen, nehmen die Bedienbarkeit als intuitiver wahr und schreiben den generierten Resultaten eine höhere Verlässlichkeit zu. Vertrauen fungiert damit als psychologische Vermittlungsgröße, indem es kognitive und wahrnehmungsbezogene Faktoren in tatsächliches Nutzungsverhalten überführt. Nur wenn Ingenieur: innen überzeigt sind, dass die Systeme zuverlässig, nachvollziehbar und sicher arbeiten, wird dieses vertrauen in eine erhöhte Nutzungshäufigkeit übergehen. Vertrauen kann somit als zentrale psychologische Voraussetzung verstanden werden, die den Übergang von potenziellem zu tatsächlichem handeln ermöglicht. Daraus ergibt sich ein theoretischer Wirkungszusammenhang, in dem ein hoher objektiver Kenntnisstand die Entwicklung eines höheren subjektiven Kenntnisstandes fördert, dieser wiederum das Vertrauen in die Technologie stärkt und Vertrauen schließlich zu einer häufigeren Nutzung generativer KI im Arbeitsprozess führt. Auf dieser Grundlage wird angenommen, dass Vertrauen eine vermittelnde Rolle im Beziehungsgefüge zwischen Wissen und Nutzen einnimmt. Entsprechend kann dies als Hypothese formuliert werden, dass Ingenieur: innen mit einem höheren gemessenen Fachwissen, ein höheres Vertrauen in die Technologie aufweisen und dies zu einer höheren Nutzungshäufigkeit generativer KI resultiert.

### *5.1.4 Anwendungsschwerpunkt generativer KI im Produktentstehungsprozess*

Im Stand der Forschung zeigt sich im ingenieurtechnischen Kontext ein klarer Trend, dass generative KI insbesondere in den frühen Phasen des Produktentstehungsprozesses Anwendung findet. Diese Tendenz wird auch durch externe systematische Literaturrecherchen bestätigt, die Anwendungsfälle generativer KI im industriellen Umfeld analysierten. Der überwiegend Anteil Use-Cases lässt sich in den frühen PEP-Phasen finden, insbesondere in der strategischen Produktplanung, Ideengenerierung und Konzeptentwicklung. In diesen Abschnitten wird generative KI vor allem eingesetzt, um kreative und analytische Aufgaben zu unterstützen, Variantenräume zu erweitern und datenbasierte Entscheidungsprozesse zu fördern. (Berger, 2024)

Auch konzeptionelle und praxisnahe Studien aus der Literaturrecherche der Arbeit verdeutlichen die besondere Bedeutung dieser frühen Prozessschritte. So zeigt das *Designer Generative AI Ideation Process-Modell,* dass der klassische Planungsprozess durch die kollaborative Interaktion zwischen Mensch und Künstlicher Intelligenz erweitert werden kann. Dadurch lassen sich Ideen effizienter, strukturierter und inspirierender entwickeln, etwa durch den gezielten Einsatz generativer Modelle wie Chat GPT oder Midjourney in der Konzept- und Planungsphase. (Kwon et. al., 2024) In ähnlicher Weise wird auch betont, dass generative KI in der Entwicklungs- und Konstruktionsphase vor allem in den frühen, konzeptionellen Abschnitten genutzt wird, um Funktions- und Gestaltungsvarianten zu erarbeiten und die Effizienz in der Ideenbewertung zu steigern. (Lin et. al., 2025)

Die Fokussierung auf diese frühen Phasen lässt sich demnach durch mehrere Faktoren erklären. Einerseits weisen diese Prozessabschnitte einen hohen explorativen Charakter auf, in dem Offenheit für kreative Lösungsansätze und flexible Informationsverarbeitung entscheidend sind. Andererseits bestehen in späteren Phasen, wie der detaillierten Konstruktion oder Produktion, noch technische oder organisatorische Einschränkungen, etwa durch unzureichend integrierte Systemumgebungen oder fehlende domänenspezifische Trainingsdaten. (Berger, 2024) Diese Erkenntnisse verdeutlichen, dass das Potenzial generativer KI aktuell vor allem in jene Tätigkeiten ausgeschöpft wird, die durch Offenheit, konzeptionelles Denken und hohe kognitive Anforderungen geprägt sind. Somit zeigt die Technologie gegenwärtig ihren Mehrwert vor allem in der methodischen Unterstützung kreativer, strategischer und analytischer Prozesse und legt dadurch einen wesentlichen Beitrag zur Effizienz- und Qualitätssteigerung in den frühen Entwicklungsstadien.

Auf Grundlage dieser theoretischen und empirisch gestützten Erkenntnisse wird angenommen, dass generative KI vornehmlich in den frühen Phasen des Produktentstehungsprozesses eingesetzt wird, insbesondere in der Produktplanung, Ideenfindung und Konzeptentwicklung. Somit wird folgende Hypothese formuliert, dass Ingenieur: innen bevorzugt generative KI in den frühen Phasen des Produktentstehungsprozess nutzen, in denen kreative und konzeptionelle Aufgaben dominieren.

### *5.1.5 Unternehmensgröße und Nutzungshäufigkeit*

Auf Basis der theoretischen Annahmen aus der Dimension zur Organisation lässt sich ableiten, dass mit zunehmender Unternehmensgröße die Nutzungshäufigkeit generativer KI steigt. Große Unternehmen verfügen über mehr Ressourcen, strukturierte Prozesse und spezialisierte

Fachabteilungen, die die Einführung und Anwendung neuer Technologien erleichtert. Ihre organisatorischen Strukturen fördern eine strategisch geplante Integration generativer KI in bestehende Arbeits- und Entwicklungsprozesse. Dabei wird betont, dass die hohe Standardisierung großer Unternehmen ihre Flexibilität einschränken kann, gleichzeitig zeigt sich auch, dass die Strukturen eine höhere Integrations- und Umsetzungskapazität bieten. Im Gegensatz dazu sind kleine und mittlere Unternehmen zwar agiler und offener für Experimente, verfügen jedoch seltener über die Mittel und Strukturen, um generative KI langfristig und systematisch zu nutzen. (Sommer, 2015; Müller, 2021) Daher lässt sich hier die Hypothese formulieren, dass mit wachsender Unternehmensgröße auch die Nutzungshäufigkeit generativer KI zunimmt.

# 6 Forschungsdesign

Das folgende Kapitel beschreibt das Forschungsdesign der vorliegenden empirischen Untersuchung, die sich mit dem Stand und dem Einsatzpotenzial generativer Künstlicher Intelligenz im Maschinenbau befasst. Es bildet die methodische Grundlage der Arbeit und erläutert das wissenschaftliche Vorgehen, das der Datenerhebung, -aufbereitung und -analyse zugrunde liegt. Ziel ist es, die methodischen Entscheidungen transparent und systematisch darzulegen, um die wissenschaftliche Güte, Nachvollziehbarkeit und Validität der Untersuchung sicherzustellen.
Das Kapitel strukturiert den Forschungsprozess von der Konzeption des Fragebogens und der Operationalisierung der Variablen über die Datenerhebung bis hin zu den angewandten Auswertungsverfahren. Der Fokus liegt dabei auf der methodischen Herleitung und Begründung der gewählten Vorgehensweise, ohne an dieser Stelle auf inhaltliche Ergebnisse oder Hypothesen einzugehen.
Damit definiert das Kapitel den methodischen Rahmen, innerhalb dessen die empirischen Befunde im folgenden Kapitel der Ergebnisse interpretiert und bewertet werden.

## 6.1 Fragenkonzeption und Operationalisierung der Variablen

In diesem Kapitel werden die Konzeption des Fragebogens, seine theoretische Fundierung, die Operationalisierung der Variablen sowie der Aufbau und die Skalierung der Messinstrumente dargestellt. Der Fragebogen bildet das zentrale Erhebungsinstrument der empirischen Untersuchung und wurde auf Grundlage konzeptioneller Überlegungen sowie der im theoretischen Teil gewonnen Erkenntnisse entwickelt. Ziel war es, zentrale Einflussfaktoren, Strukturen und Zusammenhänge in messbare Variablen zu überführen, um eine systematische und empirisch Beantwortung der Forschungsfragen zu ermöglichen.

Der Aufbau des Fragebogens orientiert sich an den zentralen Dimensionen und Themenfelder des im Kapitel zum Forschungsstand beschriebenen theoretischen Bezugsrahmens. Diese Gliederung wurde beibehalten, um eine inhaltliche Verbindung zwischen Theorie und der Empirie herzustellen. Die klare thematische Struktur unterstützt zudem einen nachvollziehbaren und flüssigen Bearbeitungsablauf für die Teilnehmenden.

Der Fragebogen umfasst somit sieben inhaltliche Abschnitte: (1) Demografie & Kontext, (2) Nutzungsstatus & Häufigkeit, (3) Einsatzfelder generativer KI, (4) Subjektiver Kenntnisstand, (5) Objektiver Kenntnisstand, (6) Einsatzpotenzial im Arbeitskontext sowie (7) Vertrauen & Risiko. Auf diese Weise ermöglicht die Struktur des Fragebogens eine systematische Erfassung des Stands und des Einsatzpotenzials generativer KI im Maschinenbau.

Zur strukturierten Dokumentation der in der Umfrage verwendeten Erhebungsinstrumente wird in dieser Arbeit ein Variablenverzeichnis erstellt (siehe Anhang A). Es dient der methodischen Transparenz und stellt die zentrale Verbindung zwischen theoretischer Konzeptionalisierung und empirische Messung her. Durch die systematische Abbildung der theoretischen Variablen in tabellarischer Form wird nachvollziehbar, wie abstrakte Konstrukte in empirisch beobachtbare Indikatoren überführt werden. Jede Zeile beschreibt eine Variable, die durch mehrere Merkmalsdimensionen charakterisiert wird. Dazu zählen das zugrunde liegende theoretische Konstrukt, die Variablenbezeichnung sowie eine eindeutige Kennung, die eine klare Zuordnung zu den jeweiligen Fragebogenitems ermöglicht. Ergänzend werden Fragentyp (z.B. Single-Choice) und Antwortformat angegeben. Darüber hinaus enthält das Verzeichnis Angaben zum Skalenniveau und Variablentyp, die die empirische Messlogik und die statistische Analysemöglichkeiten bestimmt. (Diekmann, 2017)

### *6.1.1 Themenblock 1: Demografie & Kontext*

Der erste Themenblock „Demografie & Kontext“ erfasst zentrale Merkmale der Befragten, die den Rahmen für den Einsatz generativer KI im ingenieurtechnischen Arbeitsumfeld bilden. Er umfasst sieben Variablen, die eine differenzierte Beschreibung der Stichprobe und eine fundierte Einordnung der empirischen Ergebnisse ermöglichen. Der Fokus liegt auf beschreibende Merkmale, die keine Kausalzusammenhänge abbilden, sondern der Kontextualisierung der späteren Befunde dienen. Erfasst wurden Merkmale wie Altersgruppe, Geschlecht, Arbeitsregion, Branche, berufliche Rolle, Berufserfahrung und Unternehmensgröße. Diese Variablen ermöglichen eine Analyse individueller und organisationaler Einflussfaktoren auf die Nutzung und Bewertung generativer KI. So lassen sich beispielsweise generationale, regionale oder struktu-

relle Unterschiede im Umgang mit der Technologie identifizieren. Die Variablen wurden mithilfe standardisierter fragetypen operationalisiert. Zum Einsatz kamen überwiegend Single-Choice-Formate (z.B. für Geschlecht, Altersgruppe, Unternehmensgröße) sowie Mehrfachauswahlen für die berufliche Rolle, um Mehrfachzugehörigkeiten abzubilden. Bei den Variablen Branche und Rolle wurden ergänzend Freitextfelder integriert, um eine präzisere Spezifikation zu ermöglichen. Das Skalenniveau wurde entsprechend der Messlogik zugeordnet. Altersgruppe, Berufserfahrung und Unternehmensgröße sind ordinalskaliert, alle anderen Variablen nominalskaliert. Sämtliche Variablen des Themenblocks sind kategorialer Natur.

*Tabelle 3: Variablenübersicht des Themenblocks "Demografie & Kontext". Eigene Darstellung*

| Variabel | ID | Fragentyp | Antwortformat | Skalenniveau | Variablentyp |
|---|---|---|---|---|---|
| Alter | K102 | Single Choice | 18-24/25-29/30-34/35-45/>45 | Ordinal | kategorial geordnet |
| Geschlecht | K103 | Single Choice | männlich/weiblich/divers | Nominal | kategorial |
| Arbeitsregion | K104 | Drop - down | 16 Bundesländer (DE) | Nominal | kategorial |
| Branche | K105 | Single Choice + Freitext | 4 Hauptbranchen + Sonstiges | Nominal | kategorial |
| Rolle | K106 | Multiple Choice + Freitext | vordefinierte Rollen + Sonstiges | Nominal | kategorial |
| Berufserfahrung | K107 | Single Choice | 0-2/3-5/6-10/>10/k.A. | Ordinal | kategorial geordnet |
| Unternehmensgröße | K108 | Single Choice | <50 / 50-100 / 500-1000 / k.A. | Ordinal | kategorial geordnet |

Auf diese Weise bildet der Themenblock die Grundlage für die Beschreibung der Stichprobe und dient als methodische Referenz, um spätere Zusammenhänge zwischen individuellen, organisationalen und kontextuellen Einflussgrößen im Einsatz generativer KI empirisch einordnen zu können.

### *6.1.2 Themenblock 2: Nutzungsstatus & Häufigkeit*

Der zweite Themenblock „Nutzungsstatus & Häufigkeit“ dient der Differenzierung zwischen Nutzer: innen und Nicht-Nutzer: innen generativer KI sowie der Erfassung der Nutzungshäufigkeit im ingenieurtechnischen Arbeitskontext. Zur methodischen Umsetzung wurde eine pfadgesteuerte Sprunglogik implementiert, die sicherstellt, dass die Teilnehmenden abhängig von ihren Antworten automatisch zu den jeweils relevanten Folgefragen weitergeleitet werden. Dadurch beziehen sich die nachfolgenden Fragen gezielt auf die individuelle Nutzungssituation der Befragten und gewährleisten eine kontextgerechte und effiziente Erhebung. Diese Trennung erfüllt eine zentrale methodische Funktion, da sie die inhaltliche Validität erhöht, hypothetische Bewertungen vermeidet und eine klare Grundlage für spätere Gruppenvergleiche schafft.

Erhoben wurden in diesem Themenblock die Variablen Nutzungsstatus und Nutzungshäufigkeit sowie ergänzend, im Rahmen der Sprunglogik, die Variablen Nutzungsabsicht und Barrieren bei den Nicht-Nutzer: innen. Ziel war es, ein differenziertes Bild über die tatsächliche Nutzung generativer KI, potenzielle Adoptionschancen und bestehende Nutzungshindernisse zu gewinnen. Für die Gruppe der Nutzer: innen wurde zusätzlich die Variablen Tool-Breite erhoben, die Aufschluss darüber gibt, in welchem Umfang verschiedene generative KI-Anwendungen bereits in den Arbeitsalltag integriert sind.

Zur Erhebung des Nutzungsstatus, der Nutzungshäufigkeit und der Nutzungsabsicht kamen Single-Choice-Fragen zum Einsatz, die auf einer fünfstufigen Likert-Skala basieren. Die Variablen Tool-Breite und Barrieren wurden über Multiple-Choice-Fragen mit ergänzenden Freitextfeldern operationalisiert, um individuelle und kontextspezifische Antworten zu ermöglichen. Das Skalenniveau und die Variablentypen wurden entsprechend der Messlogik zugeordnet. Der Nutzungsstatus wurde als nominale Variable erhoben, die Nutzungshäufigkeit nach Intensitätskodierung als metrisch-Verhältnisskaliert interpretiert. Die Tool-Breite stellt eine intervallskalierte (metrische) Zählervariable dar, während die Nutzungsabsicht ordinalskaliert und die Barrieren nominalskaliert sind.

*Tabelle 4: Variablenübersicht des Themenblocks "Nutzungsstatus & Häufigkeit". Eigene Darstellung*

| Variabel | ID | Fragentyp | Antwortformat | Skalenniveau | Variablentyp |
|---|---|---|---|---|---|
| Nutzungsstatus | K202 | Single Choice (Likert - System) | 1 = nie, 2 = monatlich, 3 = wöchentlich, 4 = mehrmals pro Woche, 5 = täglich | Nominal (Dichotom) | kategorial (binär) |
| Nutzungshäufigkeit | K202 | Single Choice (Likert - System) | 1 = nie, 2 = monatlich, 3 = wöchentlich, 4 = mehrmals pro Woche, 5 = täglich | Verhältnisskaliert | metrisch |
| Tool-Breite | K204 | Multiple Choice + Freitext | Vordefinierte Tool Anwendungen + individuelle Ergänzung | Intervallskaliert | metrisch |
| Nutzungsabsicht | K205 | Single Choice (Likert - System) | 1 = sehr unwahrscheinlich bis 5 = sehr wahrscheinlich | Ordinal | kategorial geordnet |
| Barriere | K206 | Multiple Choice + Freitext | Vordefinierte Gründe + individuelle Ergänzung | Nominal | kategorial |

Auf diese Weise bildet der Themenblock die Grundlage für die empirische Differenzierung zwischen Nutzer: innen und Nicht-Nutzer: innen generativer KI.

### *6.1.3 Themenblock 3: Einsatzfelder generativer KI*

Auf Grundlage der im vorangegangenen Themenblock vorgenommenen Trennung zwischen Nutzer: innen und Nicht-Nutzer: innen werden ausschließlich aktive Nutzer: innen generativer KI in den Themenblock „Einsatzfelder generativer KI“ weitergeleitet. Ziel ist die systematische Erfassung realer Einsatzfelder im ingenieurtechnischen Arbeitsalltag. Unter Einsatzfeldern werden wiederkehrende, klar abgegrenzte Tätigkeiten mit definiertem Ziel, Input und Output verstanden, beispielsweise Entwerfern, Prüfen oder Dokumentieren. Damit werden tatsächliche Nutzungsmuster auf Basis praktischer Erfahrungen abgebildet, anstatt hypothetischer Einschätzungen.

Zur strukturierten Analyse werden zwei komplementäre Betrachtungsperspektiven herangezogen, diese sind die Funktionssicht und die Prozesssicht. Erstere beschreibt die inhaltlich-fachlichen Aufgaben, also was im Arbeitskontext getan wird (z.B. Recherchieren, Entwerfen, Dokumentieren). Die Prozesssicht erfasst dagegen, wo und wann diese Tätigkeiten im Produktentstehungsprozess stattfinden (z.B. Planung, Entwicklung, Konstruktion). Beide Dimensionen werden methodisch getrennt erhoben, um Überschneidungen zu vermeiden und die Interpretierbarkeit der Ergebnisse zu gewährleisten. (Diekmann, 2017)

Zunächst wird die Funktionssicht behandelt, gefolgt von der Prozesssicht. Dieser Aufbaue basiert auf der Annahme, dass konkrete Tätigkeiten aus Erinnerungsperspektive leichter und verlässlicher abrufbar sind als deren genau Verortung im Produktentstehungsprozess. Da Aufgaben in mehreren Phasen auftreten können und jede Phase unterschiedliche Tätigkeiten umfasst, ermöglicht die Erinnerung an eine spezifische Aufgabe eine präzisere Zuordnung im Prozess. (Tourangeau et. al., 2000) Somit umfasst die Funktionssicht neun Variablen, die zentrale Tätigkeitsbereiche ingenieurtechnischer Arbeit abbildet. Die Ableitung erfolgte theoriegeleitet durch eine abstrahierende Zusammenführung industrieller Use Cases zu typischen Aufgabenfelder. Dazu zählen beispielsweise Ideengenerierung und Konzeptentwicklung, Programmierung und Skripterstellung, Recherche und Zusammenfassung, Dokumentation und Protokollierung, Qualitäts- und Sicherheitsüberprüfung, Wissensmanagement, Kommunikation und E-Mail-Korrespondenz sowie Übersetzung und Mehrsprachigkeit. (ten Hompel et. al., 2023; Morlock et. al., 2025) Diese Variablen decken ein breites Spektrum funktionaler Dimensionen ab, von kreativen über analytisch-technische bis hin zu kommunikativen Tätigkeiten und bilden damit die methodische Grundlage zur Analyse realer Anwendungsfelder generativer KI.

Die Funktionssicht wurde mittels Single-Choice-Fragen auf einer fünfstufigen Likert-Skala operationalisiert, um die Intensität der Nutzung innerhalb der jeweiligen Tätigkeitsfelder zu quantifizieren. Die Variablen sind ordinalskaliert und werden für analytische Zwecke als quasimetrisch interpretiert.

*Tabelle 5: Variablenübersicht des Themenblocks "Einsatzfelder generativer KI" (Funktionssicht). Eigene Darstellung***.**

| Variabel | ID | Fragentyp | Antwortformat | Skalenniveau | Variablentyp |
|---|---|---|---|---|---|
| Ideengenerierung / Konzeptentwicklung | K302 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| Recherche / Zusammenfassung | K303 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| Programmierung / Skripten / Fehlersuche | K304 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| CAD / CAE Unterstützung | K305 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| Dokumentation / Protokolle | K306 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| Kommunikation / E-Mails | K307 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| Übersetzung / Mehrsprachigkeit | K308 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| Qualität- / Sicherheitsreviews | K309 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |
| Wissensmanagement | K310 | Single Choice (Likert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-metrisch |

Im zweiten Abschnitt, der Prozesssicht, wird erhoben, in welchen Phasen des Produktentstehungsprozesses generative KI eingesetzt wird. Die Teilnehmenden konnten bis zu zwei Phasen auswählen, um Mehrfachanwendungen entlang des Entwicklungsprozesses abzubilden. Ergänzend wurde die Variable Priorität der Nutzung erfasst, die die Motivation für den Einsatz generativer KI beleuchtet. Hierzu bewerteten die Befragten vordefinierte Nutzenfaktoren wie Zeit-

ersparnis, Fehlerreduktion oder Qualitätssteigerung durch ein Drag-and-Drop-Ranking (Rangfolge 1-3), um Trade-offs zwischen konkurrierenden Zielen sichtbar zu machen. Ein abschließendes Freitextfeld ermöglicht die Angabe konkreter Anwendungsbeispiele, wodurch die Ergebnisse um kontextuelle und qualitative Einsichten ergänzt wurde.

*Tabelle 6: Variablenverzeichnis des Themenblocks "Einsatzfelder generativer KI" (Prozesssicht). Eigene Darstellung.*

| Variabel | ID | Fragentyp | Antwortformat | Skalenniveau | Variablentyp |
|---|---|---|---|---|---|
| PEP-Phase | K312 | Multiple-Choice (min. 2) | 5 Phasen des PEPs | Nominal | kategorial |
| Priorität der Nutzung | K313 | Ranking (Drag & Drop) | vordefinierte Zielmotivationen | Ordinal | kategorial (geordnet) |
| Recherche / Zusammenfassung | K314 | Freitextfeld | freie Beschreibung | _ | qualitativ |

Der Themenblock schafft somit eine empirische Grundlage zur systematischen Erfassung der funktionalen und prozessbezogenen Nutzung generativer KI im ingenieurtechnischen Arbeitsumfeld. Er ermöglicht eine differenzierte Analyse typischer Anwendungsfelder, Integrationsgrade und Nutzungsschwerpunkte entlang des Produktentstehungsprozesses.

### *6.1.4 Themenblock 4: Subjektiver Kenntnisstand*

Im Themenblock „Subjektiver Kenntnisstand“ werden nach der pfadgesteuerten Trennung wieder alle Teilnehmend zusammengeführt. Ziel ist die Erfassung der individuellen Selbsteinschätzungen hinsichtlich Wissens, Fähigkeiten und Anwendungssicherheit im Umgang mit generativer KI. Die Variable des subjektiven Kenntnisstandes stellt einen zentralen Einflussfaktor für den erfolgreichen Einsatz generativer KI dar. Das zugrunde liegende psychologische Konstrukt der Selbstwirksamkeit beschreibt die Überzeugung, Aufgaben aus eigener Kraft erfolgreich bewältigen zu können. Ein hohes Vertrauen in die eigenen Kompetenzen fördert aktives, zielgerichtetes Handeln, während ein geringes Kompetenzgefühl mit Unsicherheiten und Nutzungsbarrieren einhergeht. (Egger, 2020) In der Erweiterung des Technologieakzeptanzmodells nach

TAM3 wurde dieser Zusammenhang durch die Einbeziehung der Computer Self-Efficacy konkretisiert, die die individuelle Überzeugung beschreibt, digitale Technologien effektiv nutzen zu können. Personen mit höherer wahrgenommener Kompetenz empfinden technologische Anwendungen demnach als weniger komplex und zeigen folglich eine größere Nutzungsbereitschaft. (Bandow & Holzmüller, 2009) Die Erhebung erfolgt gruppenübergreifend, um Unterschiede in der Selbstwahrnehmung zwischen Nutzer: innen und Nicht-Nutzer: innen sichtbar zu machen. Während aktive Nutzer: innen ihre Einschätzung auf konkrete Erfahrungen stützen, lässt sich bei Nicht-Nutzer: innen erkennen, ob fehlendes Vertrauen in die eignen Fähigkeiten einen hemmenden Einfluss auf die Nutzung haben.

Zur Messung des subjektiven Kenntnisstandes wurden sechs Aussagen formuliert, die auf einer fünfstufigen Likert-Skala zu bewerten waren.

Diese Items orientieren sich an den theoretischen Konzepten der Selbstwirksamkeit sowie des DigiComp-Frameworks und übertragen diesen auf den Kontext generativer KI im Maschinenbau. (Egger, 2020; Bandow & Holzmüller, 2009; DigiComp, 2016)

Das Konstrukt wird als mehrdimensionales Konzept verstanden, das die wahrgenommene Kompetenz in den Bereichen Wissen, Anwendungsfähigkeit sowie Verantwortungsbewusstsein und Sicherheit abbildet.

- Die Dimension Wissen umfasst das Verständnis grundlegender Funktionsprinzipien, Stärken und Grenzen generativer KI sowie den sicheren Umgang mit Daten.
- Anwendungsfähigkeit beschreibt die Fähigkeit, Prompts zielgerichtet zu formulieren und Ergebnisse systematisch zu prüfen.
- Verantwortungsbewusstsein und Sicherheit erfasst den reflektierten und regelkonformen Umfang mit generativer KI, einschließlich der Beachtung interner Richtlinien und der Fähigkeit, Unstimmigkeiten zu erkennen.

Alle Variablen wurden im Single-Choice-Format erhoben, und ordinalskaliert. Die gleich interpretierten Abstände der Skalenpunkte erlauben eine quasi-metrische Analyse. Zur Verdichtung der Daten wurde aus den sechs Einzelaussagen ein aggregierter Kompetenzscore gebildet, der die Dimensionen zu einer Gesamtskala zusammenführt. Dieser Score stellt die zentrale Variable des Themenblocks dar und ermöglicht somit eine quantitative Bewertung des subjektiven Kenntnisstandes.

*Tabelle 7: Variablenübersicht des Themenblocks "Subjektiver Kenntnisstand". Eigene Darstellung.*

| Variabel | ID | Fragentyp | Antwort-format | Skalenni-veau | Variab-lentyp |
|---|---|---|---|---|---|
| Kompetenz-Score | Aggregierter Kompe-tenz-Score (Mittelwert aus 6 Items; K402 - K407) | Single Choice (Lik-ert-System, fünf-stufig) | 1 = stimme gar nicht zu; bis 5 = stimme voll-kommen zu | Intervallska-liert | metrisch |

### *6.1.5 Themenblock 5: Objektiver Kenntnisstand*

Der Themenblock „Objektiver Kenntnisstand“ erfasst den tatsächlichen Wissensstand der Teilnehmenden im Umgang mit generativer KI. Während im vorangegangenen Abschnitt die subjektive Selbsteinschätzung im Mittelpunkt stand, zielt dieser Themenblock darauf ab, grundlegende Fachkenntnisse und Funktionsprinzipien generativer KI zu prüfen. Er ergänzt damit die Selbsteinschätzung um ein leistungsbasiertes Messinstrument und ermöglicht eine differenzierte Gegenüberstellung zwischen wahrgenommenem und tatsächlichem Wissen.

Zur Erfassung wurden vier Aussagen formuliert, die zentrale technische Konzepte generativer Modelle abprüfen, die für den ingenieurtechnischen Arbeitskontext besonders relevant sind. Eine Aussage bezieht sich auf das Phänomen der Halluzination, also die Erzeugung inhaltlich fehlerhafter oder frei erfundener Antworten durch Sprachmodelle. (Ji et. al., 2023) Eine weitere behandelt das Verfahren der Retrieval-Augmented-Generation (RAG), bei dem Sprachmodelle durch externe Wissensquellen ergänzt werden, Faktenbezug und Nachvollziehbarkeit zu erhöhen. (Lewis et. al., 2020) Darüber hinaus wird zwischen Prompt Engineering, der gezielten Formulierung von Eingaben, und Fine-Tuning, dem Nachtrainieren eines Modells mit spezifischen Daten unterschieden, um die Differenzierung zwischen Anwendungskompetenz und Modellanpassung zu erfassen. (White et. al., 2023) Abschließend thematisiert das letzte Item die Sampling-Temperatur als Steuerungsparameter, der die Varianz und Vorhersagbarkeit generierter Inhalte beeinflusst. (Holtzman et. al., 2020)

Die Erhebung erfolgt im dreistufigen Likert-Format, das den Teilnehmenden eine Einschätzung der Aussagen ermöglicht. Dieses Format wurde bewusst gewählt, um den Charakter einer Wissensprüfung zu vermeiden und mögliche Verzerrungen durch Prüfungsdruck zu reduzieren. Gleichwohl besitzt jede Aussage einen eindeutig definierten Wahrheitsgehalt, wodurch eine

objektive Bewertung möglich ist. Auf diese Weise entsteht ein verlässliches Maß für den tatsächlichen Wissensstand, ohne dass die Befragten eine Bewertungssituation erleben.
Aus den vier Einzelaussagen wurde ein aggregierter Quiz-Score gebildet, der den objektiven Kenntnisstand der Teilnehmenden quantitative abbildet. Diese Kennzahl dient als zentrale Variable zur Messung faktischer Wissensbestände und ermöglicht eine direkte Gegenüberstellung mit dem zuvor erhobenen subjektiven Kenntnisstand.

*Tabelle 8: Variablenübersicht des Themenblocks "Objektiver Kenntnisstand". Eigene Darstellung.*

| **Variabel** | **ID** | **Fragentyp** | **Antwortformat** | **Skalenniveau** | **Variablentyp** |
|---|---|---|---|---|---|
| Quiz-Score | Aggregierter Quiz-Score (Mittelwert aus 4 Items; K502-K505) | Single Choice (Likert-System, dreistufig) | 1 = Stimme nicht zu; 2 = Teils/Teils; 3 = Stimme zu | Verhältnisskaliert | metrisch |

### *6.1.6 Themenblock 6: Einsatzpotenzial im Arbeitskontext*

Der Themenblock „Einsatzpotenzial im Arbeitskontext“ erfasst die wahrgenommene Nützlichkeit generativer KI im beruflichen Umfeld der Befragten. Während die vorherigen Themenblöcke den Nutzungsstatus sowie den subjektiven und objektiven Kenntnisstand abbildeten, steht hier die Einschätzung des potenziellen Mehrwerts generativer KI im ingenieurtechnischen Arbeitskontext im Vordergrund. Ziel ist es zu untersuchen, in welchem Maße Fachkräfte generativer KI das Potenzial zuschreiben, Arbeitsprozesse effizienter, qualitativ hochwertiger und strategisch wertvoller zu gestalten.
Zur Erhebung wurden vier Aussagen entwickelt, die unterschiedliche Dimensionen arbeitsbezogener Unterstützung abbilden. Diese wären die Effizienzsteigerung, Qualitätsverbesserung, Entscheidungsunterstützung und Wertschöpfungssteigerung durch Entlastung von Routinetätigkeiten. Gemeinsam bilden diese Items das theoretische Konstrukt des wahrgenommenen Einsatzpotenzials. Die Auswahl der Dimensionen orientiert sich an etablierten Modellen der Technologieakzeptanz, in denen wahrgenommene Effizienz-, Qualität- und Entscheidungsgewinne als zentrale Einflussgrößen identifiziert werden. (Venkatesh et. al., 2003)

Die Messung erfolgte auf einer fünfstufigen Likert-Skala, auf der die Teilnehmenden ihre Zustimmung zu den Aussagen Angaben. Auf dieser Grundlage wurde ein aggregierter Nutzenscore gebildet, der den Mittelwert der vier Items umfasst. Diese Kennzahl ermöglicht die Analyse von Unterschieden in der Wahrnehmung des Einsatzpotenzials zwischen verschiedenen Nutzergruppen und erlaubt es, Zusammenhänge zu weiteren Variablen herzustellen. Dadurch lassen sich potenzielle Wirkungsmuster und Einflussfaktoren auf die Akzeptanz und Nutzung generativer KI im Maschinenbau identifizieren.

*Tabelle 9: Variablenübersicht des Themenblocks "Einsatzpotenzial im Arbeitskontext". Eigene Darstellung.*

| **Variabel** | **ID** | **Fragentyp** | **Antwortformat** | **Skalenniveau** | **Variablentyp** |
|---|---|---|---|---|---|
| Nutzen-Score | Aggregierter Nutzen-Score (Mittelwert aus 4 Items; K602-K605) | Single Choice (Likert-System, fünfstufig) | 1 = stimme gar nicht zu; bis 5 = stimme vollkommen zu | Intervallskaliert | metrisch |

### *6.1.7 Themenblock 7: Vertrauen & Risiko*

Der Themenblock „Vertrauen & Risiko“ erfasst die bewertende Haltung der Teilnehmenden gegenüber generativer KI im beruflichen Kontext. Dabei stehen zwei Dimensionen im Mittelpunkt, das Vertrauen in die Zuverlässigkeit und Qualität von KI-Ergebnissen sowie die Wahrnehmung potenzieller Risiken beim Einsatz der Technologie. Beide Dimensionen sind zentral, um zu verstehen, in welchem Maß generative KI im ingenieurtechnischen Arbeitsumfeld akzeptiert, angewendet oder kritisch reflektiert wird.

Die Dimension Vertrauen bezieht sich auf die Einschätzung, inwiefern generative KI als verlässlich, nachvollziehbar und reproduzierbar wahrgenommen wird. Die zugehörigen Aussagen adressieren insbesondere das Vertrauen in die technische Zuverlässigkeit, die fachliche kontrollierte Anwendbarkeit, die Transparenz durch Quellenangaben sowie die Reproduzierbarkeit der Resultate. Die Dimension Risiko erfasst hingegen die kritische Wahrnehmung potenzieller Gefahren im Zusammenhang mit der Nutzung generativer KI. Sie umfasst Aspekte wie Datenschutz und Vertraulichkeit, geistiges Eigentum und Urheberrecht, Haftung und Compliance, Qualitäts- und Sicherheitsrisiken sowie Fehlinformationen oder Verzerrungen in den Ergebnis-

sen (Morlock et. al., 2025). Die Erhebung beider Dimensionen wurden entsprechend in Aussagen formuliert und auf einer fünfstufigen Likert-Skale bewertet. Die Dimension Vertrauen umfasst vier, die Dimension Risiko fünf Items. Aus den Mittelwerten, der jeweiligen Items wurden ein Vertrauensscore und ein Risikoscore gebildet, die eine quantitative Erfassung der allgemeinen Haltung gegenüber generativer KI ermöglichen. Diese Kennzahlen erlauben sowohl die Analyse von Gruppenunterschieden als auch den Vergleich mit weiteren Variablen wie dem Kompetenzstand oder dem wahrgenommen Nutzen.

*Tabelle 10: Variablenübersicht des Themenblocks "Vertrauen & Risiko". Eigene Darstellung.*

| Variabel | ID | Fragentyp | Antwortformat | Skalenniveau | Variablentyp |
|---|---|---|---|---|---|
| Vertrauens-Score | Aggregierter Nutzen-Score (Mittelwert aus 4 Items; K702-K705) | Single Choice (Likert-System, fünfstufig) | 1 = stimme gar nicht zu; bis 5 = stimme vollkommen zu | Intervallskaliert | metrisch |
| Risiko-Score | Aggregierter Nutzen-Score (Mittelwert aus 5 Items; K706-K710) | Single Choice (Likert-System, fünfstufig) | 1 = stimme gar nicht zu; bis 5 = stimme vollkommen zu | Intervallskaliert | metrisch |

Der Themenblock leistet somit einen zentralen Beitrag zu Erklärung des wahrgenommenen Einsatzpotenzials, indem er die Balance zwischen Vertrauen und Risiko sichtbar macht und aufzeigt, welche psychologischen und regulatorischen Faktoren die Akzeptanz und Nutzung generativer KI im ingenieurtechnischen Arbeitsumfeld beeinflussen.

## 6.2 Datenerhebung

Im Rahmen der empirischen Untersuchung wurde eine quantitative Online-Befragung durchgeführt, um den Stand und das Einsatzpotenzial generativer KI im Maschinenbau systematisch zu erfassen. Die Datenerhebung erfolgte mithilfe der Software SoSci-Survey, einem im akademischen Umfeld etablierten Online-Tool, das speziell für die Durchführung standardisierter Befragungen in wissenschaftlichen Forschungsarbeiten konzipiert ist. Die Wahl des Erhebungsinstruments ermöglichte eine effiziente Datenerhebung, eine automatisierte Auswertung sowie eine hohe methodischen Qualität durch eine klare Strukturierung und Kontrolle der Antwortlogik.

Der Erhebungszeitraum erstreckte sich über zwei Wochen, vom 19. September bis zum 3. Oktober des Jahres 2025, wodurch den Teilnehmenden ein angemessener Zeitraum zur Beantwortung zur Verfügung stand. Die Zielgruppe umfasst Ingenieur: innen und angehende Ingenieur: innen mit fachlichem Hintergrund im Maschinenbau oder verwandten ingenieur-technischen Tätigkeitsfeldern. Damit richtete sich die Befragung gezielt an Personen, die mit den technologischen, organisatorischen und methodischen Aspekten ingenieurtechnischer Arbeit vertraut sind und potenziell Berührungspunkte mit generativer KI-Systemen aufweisen.

Die Verteilung des Fragebogens erfolgte über digitale Kanäle, insbesondere über das berufliche Netzwerk LinkedIn sowie über hochschulinterne Kommunikationsforen der Hochschule Ruhr West (HRW). Der Zugang zur Befragung wurde über einen offenen Link bereitgestellt, um eine breite Streuung und heterogene Stichprobe zu ermöglichen. Eine verbindliche Mindeststichprobengröße wurde im Vorfeld nicht festgelegt, jedoch galt ein Richtwert von mindestens 30 vollständig ausgefüllten Fragebögen als erforderlich, um eine erste deskriptive und explorative Analyse zu gewährleisten.

Die Teilnahme an der Befragung war freiwillig und vollständig anonym. Die Erhebung erfolgte in Übereinstimmung mit den Vorgaben der Datenschutz-Grundverordnung (DSGVO). Es wurden keine personenbezogenen Daten erhoben, die Rückschlüsse auf einzelne Teilnehmen-de zulassen. Zu Beginn der Befragung erhielten die Teilnehmenden eine Transparenzinformation über Ziel, Zweck und Umfang der Untersuchung sowie über die datenschutzrechtliche Bestimmung. Mit dem Weiterschalten zum Fragebogen gaben sie ihre Einwilligungen zur Teilnahme, womit den ethischen und datenschutzrechtlichen Anforderungen an wissenschaftlichen Erhebungen Rechnung getragen wurde.

### 6.3 Auswertungsverfahren

Im Anschluss an die Datenerhebung werden in diesem Kapitel die angewandten Auswertungsverfahren beschrieben. Ziel ist die transparente Darstellung der methodischen Schritte von der Aufbereitung über die Beschreibung bis hin zur statistischen Analyse der erhobenen Daten. Somit gliedert sich das Kapitel in die Abschnitte zur Datenaufbereitung, der deskriptiven Statistik sowie der Inferenzstatistik. Auf diese Weise schafft das Kapitel die methodische Grundlage für die anschließende Ergebnisdarstellung.

### *6.3.1 Datenaufbereitung*

Die Auswertung der empirischen Untersuchung beginnt mit der Datenaufbereitung und -bereinigung. Die im Rahmen der Onlineumfrage generierten Rohdaten wurden aus der Erhebungsplattform SoSci-Survey exportiert und in einer Excel-Datei strukturiert aufbereitet. Anschließend erfolgte eine Qualitätsprüfung der Datensätze, bei der unvollständige oder abgebrochene Teilnahmen identifiziert und ausgeschlossen wurden, um ausschließlich vollständige und valide Datensätze in die Analyse einzubeziehen.

Im weiteren Verlauf wurden die erhobenen Umfragedaten für die statistische Analyse aufbereitet und vereinheitlicht. Dazu gehörten die Überprüfung auf fehlende Werte, die Rekodierung kategorialer Variablen sowie die Aggregation von Einzelfragen zu Skalenwerten. Eine detaillierte Übersicht der Kodierungen der einzelnen Variablen und Themenblöcke findet sich im Anhang wieder (siehe Anhang A).

Ordinale Likert-Skalen (z.B. 1 = stimme gar nicht zu bis 5 = stimme vollkommen zu) wurden numerisch in monoton steigender Reihenfolge von 1 bis 5 kodiert, um ihre statistische Auswertbarkeit sicherzustellen. Im Sonderfall der Nutzungshäufigkeit generativer KI erfolgte eine Intensitätskodierung, bei der die Antwortkategorien in eine Nutzungsfrequenz pro 30 Tage überführt wurde, um die tatsächliche Nutzung quantitativ abbilden zu können. Dabei wurde eine numerische Zuordnung vorgenommen, die die Häufigkeit der Nutzung widerspiegelt.

Nominale Variablen ohne natürliche Rangordnung, wie etwa das Geschlecht oder Branche, wurden dummy-kodiert, um sie in inferenzstatistischen Verfahren berücksichtigen zu können. Dabei repräsentiert der jeweilige Dummy-Koeffizient den Unterschied der entsprechenden Kategorie zur definierten Referenzgruppe. Fehlende Werte infolge unbeantworteter Fragen wurden als System Missing Values gekennzeichnet und in den Analysen entsprechend behandelt, um Verzerrungen der Ergebnisse zu vermeiden.

Ein besonderer Fall betraf die Kodierung der Variablen im Themenblock (Objektiver Kenntnisstand). Die dort enthaltenen Aussagen wurden in einem dreistufigen Likert-System erhoben und anhand ihres faktischen Wahrheitsgehalts bewertet. Für jedes Item wurde ein korrekter Wahrheitswert definiert, der mit 1 kodiert wurde, während die beiden übrigen Antwortoptionen den Wert 0 erhielten. Dieses Scoring soll eine objektive Beurteilung des Fachwissens der Teilnehmenden ermöglichen, in dem richtige von falscher Einschätzung unterschieden werden.

Zur Überprüfung der internen Konsistenz der verwendeten Skalen wurde eine Reliabilitätsanalyse mithilfe von Cronbachs Alpha durchgeführt. Dieses Verfahren basiert auf der klassischen

Testtheorie und dient der Beurteilung, inwieweit die einzelnen Items eines Themenblocks dasselbe theoretische Konstrukt erfassen und somit eine homogene Skala bilden. Werte ab 0,7 gelten als akzeptabel, ab 0,8 als gut und ab 0,9 als sehr hoch. Die Reliabilitätsanalyse wurde für alle mehrdimensionalen Skalen separat vorgenommen, um deren interne Konsistenz empirisch zu prüfen und gegebenenfalls schwache Items zu identifizieren. (Bühner, 2011)

Diese Schritte der Datenaufbereitung, Kodierung und Reliabilitätsanalyse bilden die methodische Grundlage der nachfolgenden statistischen Auswertung und gewährleisten die Validität der erhobenen Daten.

### *6.3.2 Deskriptive Statistik*

Nach Abschluss der Datenaufbereitung folgt im nächsten Schritt die deskriptive Auswertung der erhobenen Variablen. Die deskriptive Statistik bildet den ersten Analyseschritt der empirischen Auswertung und dient der systematischen Beschreibung der erhobenen Daten. Ziel ist es, Tendenzen, Verteilungen und Streuungen der Variablen darzustellen, um ein grundlegendes Verständnis der Stichprobenzusammensetzung und der erhobenen Merkmalsausprägungen zu gewinnen. (Brotz & Schuster, 2010; Backhaus et. al., 2021)

In der vorliegenden Untersuchung umfasst die deskriptive Analyse ausschließlich kategoriale Variablen, die im Rahmen der demografischen und kontextbezogenen Datenerhebung erfasst wurden. Dazu zählen Merkmale wie Geschlecht, Altersgruppe, Arbeitsregion, Branche, berufliche Rolle, Berufserfahrung und Unternehmensgröße. Diese Variablen werden in Form absoluter und relativer Häufigkeiten beschrieben, wodurch Verteilungen und Dominanzen innerhalb der Stichprobe sichtbar werden. Für Ordinalskalierte Merkmale, wie etwa Berufserfahrung oder Unternehmensgröße, werden ergänzend Medianwerte herangezogen, um zentrale Tendenzen innerhalb der geordneten Kategorie zu verdeutlichen. (Brotz & Schuster, 2010)

Die deskriptive Statistik erfüllt dabei eine vorbereitende und strukturierende Funktion. Sie dient sowohl der Darstellung der Stichprobenzusammensetzung als auch der Identifikation potenzieller Verzerrungen, etwa durch unausgeglichene Verteilungen in Geschlecht oder Branche. Diese Analyse bildet die Grundlage für die anschließende inferenzstatistischen Verfahren, die auf der beschriebenen Datenbasis aufbauen und Hypothesen über Zusammenhänge oder Unterschiede zwischen Variablen prüfen. (Moosbrugger et. al., 2012) Auf diese Weise schafft die deskriptive Statistik Transparenz über die erhobenen Daten und ermöglicht einen systematischen Überblick über die Struktur der Stichprobe, bevor im folgenden Schritt inferenzstatistische Analysen zur Beantwortung der Forschungsfragen durchgeführt werden.

### *6.3.3 Inferenzstatistische Verfahren*

Aufbauend auf der deskriptiven Darstellung der Stichprobe erfolgt im nächsten Schritt die Anwendung inferenzstatistischer Verfahren. Während die deskriptive Statistik ausschließlich der erhobenen Daten beschreibt, verfolgt die Inferenzstatistik das Ziel, Rückschlüsse von der Stichprobe auf die Grundgesamtheit zu ziehen und die im theoretischen Teil formulierten Hypothesen empirisch zu überprüfen. (Bortz & Schuster, 2010)

Sie ermöglichen eine bewertende Analyse, indem sie prüft, ob beobachtete Unterschiede oder Zusammenhänge zwischen Variablen statistisch signifikant sind und nicht zufällig zustande gekommen sein könnten. (Backhaus et. al., 2021) In der vorliegenden Untersuchung werden sämtliche Themenblöcke der empirischen Erhebung in die inferenzstatistische Analyse einbezogen. Diese umfassen sowohl kategoriale als auch metrische Variablen, die je nach Skalenniveau mit geeigneten Testverfahren ausgewertet werden. Die Auswahl der Verfahren richtet sich nach den zugrunde liegenden Annahmen über Skalenniveau, Verteilung und Unabhängigkeit der Stichprobe, um eine methodisch valide und skalengerechte Analyse sicherzustellen. (Moosbrugger et. al., 2012)

Für kategoriale Variablen kommen nichtparametrische Verfahren zum Einsatz, die keine Normalverteilungsannahme erfordern. Das zentrale Verfahren in diesem Bereich ist der Chi-Quadrat-Test der Unabhängigkeit, mit dem geprüft wird, ob zwischen zwei kategorialen Merkmalen ein statistischer Zusammenhang besteht. Dabei werden die beobachteten Häufigkeiten den unter der Annahme der Unabhängigkeit erwarteten Häufigkeiten gegenübergestellt. Weichen diese signifikant voneinander ab, lässt sich auf eine systematische Abhängigkeit schließen. (Backhaus et. al., 2021; Bortz & Schuster, 2010)

Für Variablen mit metrischem Skalenniveau oder solche, die auf Likert-Skalen basieren und als intervallskaliert interpretiert werden können, werden parametrische Verfahren angewendet. Diese setzen bestimmte Verteilungsannahmen voraus und ermöglichen die Analyse von Mittelwertunterschieden sowie linearen Zusammenhängen. Ein zentrales Verfahren ist der t-Test für unabhängige Stichproben, mit dem geprüft wird, ob sich die Mittelwerte zweier Gruppen hinsichtlich einer abhängigen Variablen signifikant unterscheiden. Grundlage bildet der Vergleich der Mittelwertdifferenz in Relation zur Streuung innerhalb der Gruppen. (Backhaus et. al., 2021)

Werden die Voraussetzungen parametrischer Verfahren, insbesondere Normalverteilung und Varianzhomogenität, nicht erfüllt oder liegen ordinale Daten vor, wird auf nichtparametrische Alternativen wie den Mann-Whitney-U-Test zurückgegriffen. Dieses Verfahren vergleicht die

Rangverteilungen zweier unabhängiger Stichproben und prüft, ob sich deren Werteverteilungen systematisch unterscheiden. Es eignet sich insbesondere für kleinere Stichproben oder bei Verletzungen der Normalverteilungsannahme und ermöglicht robuste Gruppenvergleiche. (Bühner, 2011)

Zur Analyse von Zusammenhängen zwischen zwei metrischen oder ordinalen Variablen werden Korrelationsanalysen eingesetzt, die Stärke und Richtung der Beziehung zwischen zwei Merkmalen quantifizieren. Die Pearson-Korrelation wird bei metrisch skalierten Variablen verwendet, während Spearman-Rangkorrelation bei ordinalen oder nicht normalverteilten Daten Anwendung findet. Der Korrelationskoeffizient nimmt Werte zwischen -1 und +1 an, wobei das Vorzeichen die Richtung und der Betrag die Stärke des Zusammenhangs angibt. (Backhaus et. al., 2021; Moosbrugger et. al., 2012)

Zusammenfassend ermöglichen inferenzstatistische Verfahren, über die reine Beschreibung der Daten hinaus, statistische überprüfbare Aussagen über Unterschiede, Zusammenhänge und Abhängigkeiten zwischen Variablen zu treffen. Sie bilden die methodische Grundlage, um die Forschungsfragen dieser Arbeit empirisch zu beantworten und die theoretisch abgeleiteten Hypothesen zu prüfen. Die Kombination aus parametrischen und nichtparametrischen Verfahren gewährleistet dabei eine methodisch robuste und dem Skalenniveau der Daten angemessene Analyse. Die dargestellten Verfahren bilden dabei den methodischen Rahmen der möglichen Auswertungsansätze, die im Rahmen der empirischen Untersuchung zur Anwendung kommen können. Die Auswahl und tatsächliche Anwendung einzelner Verfahren erfolgt in Abhängigkeit von den spezifischen Anforderungen der jeweiligen Analyse und wird im Ergebnisteil entsprechend ausgewiesen.

# 7 Ergebnisse

Im vorliegenden Kapitel werden die Ergebnisse der empirischen Untersuchung dargestellt und ausgewertet. Nach Abschluss der Datenerhebung erfolgt zunächst eine Sichtung und Aufbereitung der erhobenen Datensätze, um die Grundlage für die anschließende deskriptive und inferenzstatistische Analyse zu schaffen. Ziel dieses Kapitels ist es, die gewonnenen Daten systematisch zu beschreiben, auf ihre Qualität zu prüfen und sie im Hinblick auf die Forschungsfragen und Hypothesen der Arbeit auszuwerten.

Der eingesetzte Online-Fragebogen wurde im Erhebungszeitraum insgesamt 123-mal aufgerufen. Diese Zahl ist jedoch nur bedingt aussagekräftig, da die Erfassung auf der Ebene der Seitenaufrufe erfolgt und somit auch mehrfache oder versehentliche Aufrufe einzelner Teilnehmender in die Zählung einfließen. Aus diesem Grund kann die Anzahl der tatsächlichen Interaktionen mit der Umfrage nicht unmittelbar aus der Zahl der Aufrufe abgeleitete werden.

Insgesamt gingen 45 ausgefüllte Fragebögen in die Datenerhebung ein. Im Anschluss wurde eine Datenbereinigung durchgeführt, um die Qualität und Vollständigkeit der erhobenen Informationen sicherzustellen. Dabei wurden unvollständige oder fehlerhafte Datensätze identifiziert und ausgeschlossen. Nach dieser Überprüfung wurden 5 Fälle aufgrund unvollständiger Angaben aus der weiteren Analyse entfernt. Somit umfasst die finale Datengrundlage n = 40 gültige Fälle, die in die statistische Auswertung einbezogen wurden. Diese Stichprobengröße liegt im erwarteten Bereich, wie bereits im Kapitel zum Forschungsdesign erläutert, und übertrifft die zuvor angestrebte Annahme einer Mindestanzahl von 30 Datensätzen.

Ergänzend wird an dieser Stelle die interne Konsistenz einzelner Themenblöcke überprüft, um die Zuverlässigkeit der verwendeten Skalen sicherzustellen. Zur Beurteilung der internen Konsistenz wird das Verfahren nach Cronbach herangezogen, das in der sozial- und verhaltenswissenschaftlichen Forschung als Standardmaß der Reliabilität gilt. Cronbachs Alpha beschreibt den Grad, zu der mehrere Items eines Fragebogens dasselbe latente Konstrukt erfassen. Es basiert auf der Annahme, dass die einzelnen Items eines Themenblocks positiv miteinander korrelieren, sofern sie dasselbe Merkmal messen. (Bortz & Schuster, 2010) Das Maß gibt an, wie homogen die Antworten über alle Items einer Skala hinweg ausfallen, und kann Werte zwischen 0 und 1 annehmen. Ein Wert ab $\alpha \geq 0{,}7$ gilt in der Regel als Indikator für eine akzeptable interne Konsistenz, Werte über $\alpha \geq 0{,}8$ werden als gute Reliabilität interpretiert. (Moosbrugger & Kelava, 2012) Die Berechnung erfolgt auf Basis der Item Varianzen und der Gesamtvarianz der Skala. Je stärker die Items miteinander korrelieren, desto höher ist der Alpha-Wert. Ein sehr

hoher Wert ($\alpha > 0{,}95$) kann hingegen auf eine redundante Item Struktur hinweisen, also darauf, dass mehrere Fragen oder Aussagen nahezu identische Inhalte abbilden. (Backhaus et. al., 2021)

In der vorliegenden Untersuchung wird Cronbachs Alpha für jene Themenblöcke berechnet, die aus mehreren Items bestehen und ein gemeinsames Konstrukt abbilden. Hierzu zählen der subjektive Kenntnisstand, der über mehrere Aussagen zur Selbsteinschätzung des eigenen Wissens im Umgang mit generativer KI erfasst wurde, der Vertrauensscore, der das Vertrauen in die Ergebnisse und Funktionsweise generativer KI abbildet, sowie der Risikowahrnehmungsscore, der die Einschätzung potenzieller Risiken und Unsicherheiten im Umgang mit generativer KI erfasst. Darüber hinaus wird auch für den Themenblock Einsatzpotenzial, aus dem die Variable Nutzenscore aggregiert wird, eine Prüfung der internen Konsistenz vorgenommen. Die Durchführung dieser Reliabilitätsprüfung ist notwendig, um sicherzustellen, dass die jeweiligen Items innerhalb eines Themenblocks tatsächlich ein einheitliches Konstrukt messen und somit zu einer aussagekräftigen Skalenbildung geeignet sind. Nur bei nachgewiesener interner Konsistenz können die Skalenwerte in den anschließenden inferenzstatistischen Analysen weiterverwendet und inhaltlich valide interpretiert werden. Die Berechnung von Cronbachs Alpha bildet somit einen zentralen Zwischenschritt zwischen der Datenerhebung und der statistischen Analyse und gewährleistet die methodische Qualität der Untersuchung.

Für den Themenblock subjektiver Kenntnisstand wurde zur Überprüfung der internen Konsistenz der zugehörigen Items der Reliabilitätskoeffizient nach Cronbach berechnet. Der errechnete Wert beträgt $\alpha = 0{,}85$, womit die Skala eine gute interne Konsistenz aufweist. Nach den Bewertungsrichtlinien liegt der Wert damit deutlich über der Mindestschwelle von 0,7, die als Indikator für eine akzeptable Reliabilität gilt, und erreicht den Bereich, der eine verlässliche und homogene Messung des zugrunde liegenden Konstrukts bestätigt.

Im Themenblock Vertrauen und Risiko wurde die interne Konsistenz zweier Skalen überprüft, die unterschiedliche Konstrukte abbilden. Für den abgeleiteten Vertrauensscore ergab die Berechnung von Cronbachs Alpha einen Wert von $= 0{,}7$, was nach den gängigen Güterkriterien als akzeptable interne Konsistenz zu bewerten ist. Die Items des Vertrauensscore korrelieren somit in hinreichendem Maß miteinander und erfassen das Konstrukt Vertrauen in generative KI konsistent. Gleichwohl liegt der Wert am unteren Rand des empfohlenen Bereichs, sodass in zukünftigen Erhebungen durch eine Erweiterung oder inhaltliche Präzisierung der Items eine Verbesserung der Messgenauigkeit erzielt werden könnte. Für den Risikowahrnehmungsscore,

der im selben Themenblock das Wahrgenommene Risiko im Umgang mit generativer KI erfasst, wurde ein Cronbachs Alpha Wert von $\alpha = 0{,}76$ berechnet. Dieser Wert liegt über den genannten Mindestwert von 0,7 und weist damit auf eine gute interne Konsistenz der Skala hin. Die einzelnen Items korrelieren somit ausreichend stark miteinander und bilden ein homogenes, theoretisch klar abgegrenztes Konstrukt.

Ergänzend wurde für den Themenblock Einsatzpotenzial im Arbeitskontext die interne Konsistenz des daraus gebildeten Nutzenscore überprüft. Mit einem berechneten Wert von $\alpha = 0{,}87$ zeigt die Skala eine hohe Reliabilität und damit eine ausgeprägte Homogenität der Items. Insgesamt weisen die durchgeführten Reliabilitätsanalysen eine zufriedenstellende interne Konsistenz der eingesetzten Skalen auf. Damit erfüllen die verwendeten Messinstrumente die grundlegenden Anforderungen an Reliabilität und Messgenauigkeit, sodass ihre Ergebnisse als methodisch belastbar gelten können. Die Skalen sind somit geeignet, in den nachfolgenden inferenzstatistischen Analyse herangezogen zu werden, um die Zusammenhänge zwischen den erhobenen Variablen empirisch zu untersuchen.

## 7.1 Deskriptive Darstellung der Stichprobe

Im Folgenden werden die Ergebnisse der deskriptiven Statistik dargestellt, die der Charakterisierung der Stichprobe dienen. Die Analyse beschreibt zentrale demografische und kontextuelle Merkmale der Teilnehmenden, um die Zusammensetzung der erhobenen Datenbasis transparent zu machen und eine Einordnung der nachfolgenden Befunde zum Einsatz generativer Künstlicher Intelligenz im Maschinenbau zu ermöglichen. Zunächst wird die Verteilung der Teilnehmenden nach Geschlecht beschrieben.

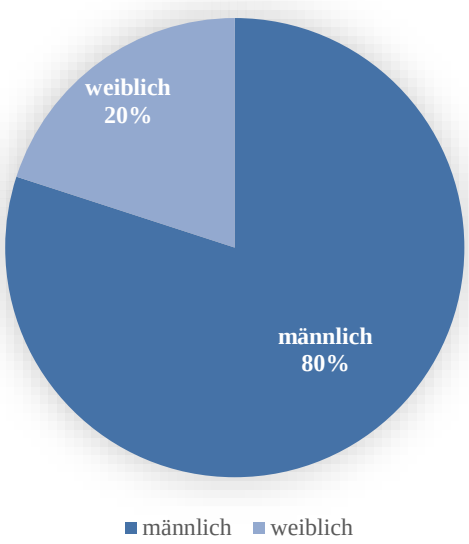


*Abbildung 4: Geschlechterverteilung der Stichprobe. Eigene Darstellung*

Auf Grundlage der absoluten Häufigkeiten der insgesamt $n = 40$ Teilnehmenden ergibt sich eine Verteilung von 32 männlichen und 8 weiblichen Befragten. Dies entspricht einer relativen Häufigkeit von 80% männlich und 20% weiblich, wie in Abbildung 4 dargestellt wird.
Die Ergebnisse zeigen ein deutlich unausgeglichene Geschlechterverteilung, das jedoch der in der Literatur beschriebenen strukturellen Zusammensetzung technischer Berufsfelder entspricht. Der Maschinenbau gilt nach wie vor als männlich dominierte Disziplin, in der Frauen anteilig stark unterrepräsentiert sind. (Bundesagentur für Arbeit, 2025) Die Dominanz männlicher Teilnehmender ist daher nicht als Stichprobenverzerrung zu interpretieren, sondern spiegelt die demografische Realität technischer Berufsgruppen im Maschinenbau wider.
Im Anschluss an die Geschlechterverteilung wurde die Altersstruktur der Befragten analysiert, um die Zusammensetzung der Stichprobe im Hinblick auf mögliche generationsspezifische Unterschiede in der Nutzung und Wahrnehmung generativer KI zu beschreiben. Die Erhebung umfasst fünf Alterskategorien (siehe Anhang A), die eine differenzierte Betrachtung verschiedener Berufseinstiegs- und Erfahrungsphasen ermöglichen.

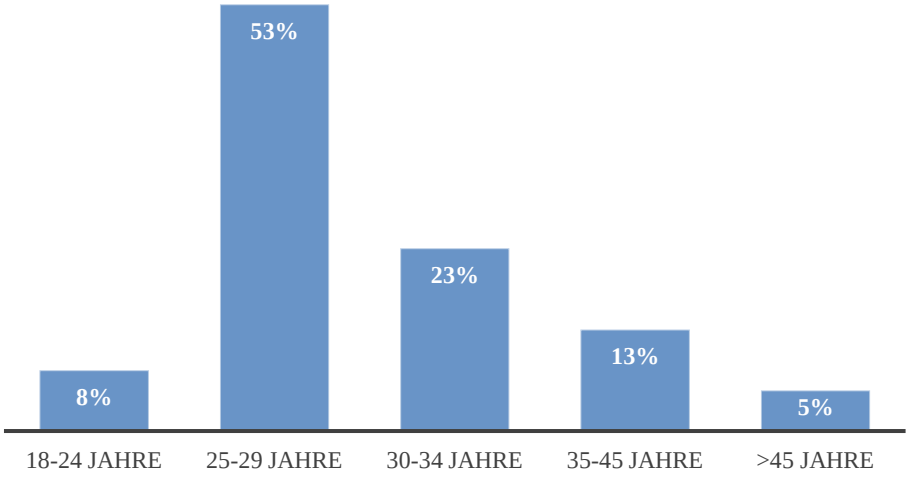


*Abbildung 5: Altersverteilung der Stichprobe. Eigene Darstellung*

Die Ergebnisse zeigen eine deutliche Konzentration in den jüngeren Altersgruppen. Mit 53% stellt die Altersgruppe der 25- bis 29-Jährigen die größte Teilgruppe, gefolgt von den 30- bis 34-Jährigen mit 23%. 13% der Befragten gehören der Altersgruppe 35 bis 45 Jahre an, während die 18- bis 24-Jährigen und die über 46-Jährigen mit 5% bzw. 8% vergleichsweise gering vertreten sind. Der berechnete Median liegt bei einem Wert von 2, was der Altersgruppe der 25- bis 29-Jährigen entspricht. Damit befindet sich der zentrale Wert der Verteilung im unteren

Drittel der möglichen Altersausprägungen und weist auf eine insgesamt tendenziell junge Stichprobe hin. Dies lässt darauf schließen, dass die Mehrheit der Befragten in den frühen beruflichen Erfahrungsphasen zugeordnet werden können.

Ergänzend zur Altersstruktur wird die Annahme geprüft, dass sich die Stichprobe in frühen beruflichen Erfahrungsphasen befindet. Zu diesem Zweck wird die erhobene Variable Berufserfahrung herangezogen, um das berufliche Erfahrungsniveau der Teilnehmenden zu beschreiben. Die Variable wurde in fünf Kategorien erhoben (siehe Anhang A), wodurch eine differenzierte Betrachtung verschiedener Karrierestufen ermöglicht wird.

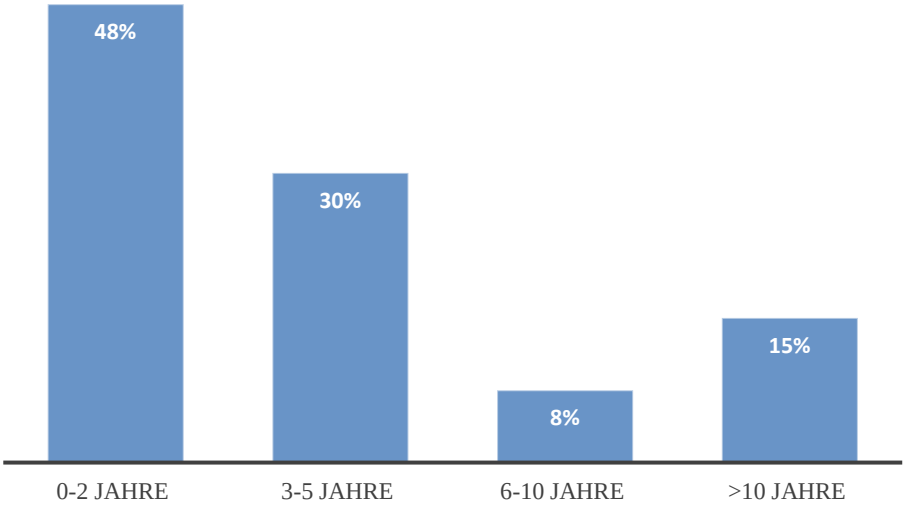


*Abbildung 6: Berufserfahrung der Stichprobe. Eigene Darstellung*

Die Ergebnisse zeigen, dass der überwiegende Teil der Stichprobe über geringe Berufserfahrung verfügt. 48% der Befragten befinden sich in der Kategorie 0 bis 2 Jahre, gefolgt von 30% mit 3 bis 5 Jahren Berufserfahrung. 8% der Teilnehmenden verfügen über 6 bis 10 Jahre und 15% über mehr als 10 Jahre Berufserfahrung. Der berechnete Median liegt bei einem Wert von 2 und entspricht damit der Kategorie 3 bis 5 Jahre Berufserfahrung. Somit liegt der zentrale Erfahrungswert im unteren Bereich der Berufserfahrungsskala und verdeutlich, dass die Stichprobe überwiegend aus Personen in frühen beruflichen Entwicklungsphasen besteht.

Im Zusammenspiel mit der zuvor dargestellten Altersverteilung deutet dieses Ergebnis darauf hin, dass die Stichprobe aus jüngeren Fachkräften in frühen Berufsjahren besteht. In Anlehnung an das Novice-to-Expert-Modell zeigt sich, das die stufenweise Entwicklung beruflicher Kompetenz auf Grundlage zunehmender Erfahrung und reflektierter Handlungspraxis beruht. Dadurch lässt sich der berufliche Erfahrungsgrad der Teilnehmenden theoretisch einordnen.

Das Modell geht von einem allgemeinen Fähigkeitskonzept aus, das die progressive Ausbildung von Expertise durch kontinuierliches Erfahrungslernen und situative Anwendung erklärt. Diese Logik lässt sich auch auf ingenieurtechnische Tätigkeiten übertragen, bei denen Fachwissen und Handlungskompetenz durch praktische Erfahrungen und kontextbezogenes Lernen wachsen. Der in der Untersuchung ermittelte zentrale Erfahrungswert von 3-5 Jahren Berufserfahrung kann somit der Stufe eines fortgeschrittenen Anfängers eingeordnet werden. (Benner, 1984; Dreyfus & Dreyfus, 1980)

Daraus lässt sich schließen, dass die Stichprobe überwiegend Personen umfasst, die über erste Praxiserfahrungen verfügen, jedoch noch in der Entwicklung routinierter, erfahrungsbasierter Handlungskompetenzen stehen. Insbesondere im Kontext der Nutzung generativer KI ist diese Zusammensetzung relevant, da sich in dieser Phase eine hohe Lern- und Technologieoffenheit beobachten lässt, gleichzeitig aber noch begrenzte Anwendungserfahrung besteht. Damit liefert sie einen wichtigen Hinweis auf das Kompetenzprofil der Befragten und die potenzielle Aufgeschlossenheit gegenüber neuen Technologien.

Im nächsten Schritt wurde die geografische Verteilung der Teilnehmenden analysiert, um den regionalen Kontext der Stichprobe zu erfassen. Die Arbeitsregionen wurden anhand der Bundesländer kategorisiert (siehe Anhang A).

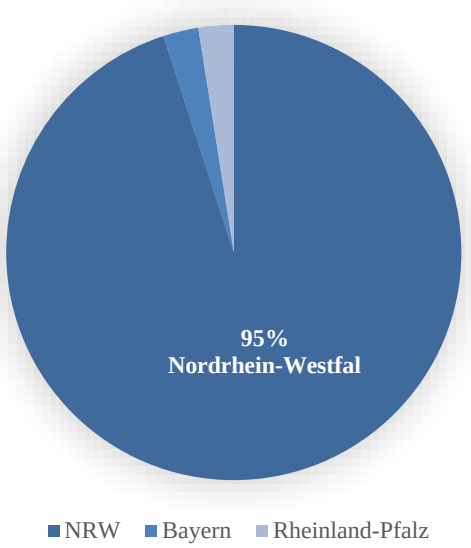


*Abbildung 7: Regionale Verteilung der Stichprobe. Eigene Darstellung*

Die Ergebnisse zeigen eine deutliche Konzentration in Nordrhein-Westfalen, das mit einer relativen Häufigkeit von 95% den überwiegenden Teil der Stichprobe ausmacht. Lediglich jeweils 2,5% der Befragten gaben Bayern bzw. Rheinland-Pfalz als aktuelle Arbeitsregion an.

Wie in Abbildung 7 dargestellt, ergibt sich somit ein klarer regionaler Schwerpunkt in Nordrhein-Westfalen.

Diese dominante Repräsentation lässt sich durch die Verbreitungswege der Umfrage erklären, die primär über das berufliche Netzwerk LinkedIn sowie hochschulinterne Kanäle der Hochschule Ruhr West erfolgte. Die daraus resultierende regionale Konzentration stellt daher keinen systematischen Stichprobenfehler dar, sondern eine kontextbedingte Verzerrung des Erhebungsumfeldes, die die reale Verankerung der Erhebung im regionalen Forschungs- und Praxisumfeldes widerspiegelt.

Im Anschluss wurde die Branchenzugehörigkeit der Teilnehmenden analysiert, um den beruflichen Kontext und die industrielle Einbindung der Befragten im Maschinenbauumfeld zu charakterisieren. Diese Variable ermöglicht die Einordnung potenzieller branchenspezifischer Unterschiede in der Nutzung und Wahrnehmung generativer KI.

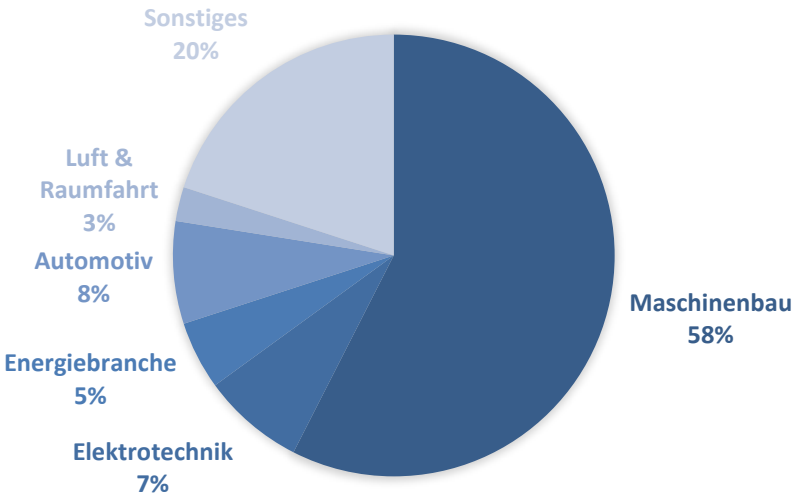


*Abbildung 8: Branchenverteilung der Stichprobe. Eigene Darstellung*

Die Ergebnisse zeigen, dass der überwiegende Teil der Befragten im klassischen Maschinenbau tätig ist. Mit einem Anteil von 62,5% stellt diese Gruppe den größten Teil der Stichprobe dar. Weitere relevante Anteile entfallen auf die Elektrotechnik (10%), den Automotive-Bereich (7,5%) sowie die Energiebranche (5%). Einzelne Nennungen stammen aus der Luft- und Raumfahrtindustrie (2,5%) sowie aus branchenübergreifenden Tätigkeitsfeldern (12,5%), die unter anderem Bildungseinrichtungen, IT-Softwareentwicklungen und Infrastruktur umfassen.

Wie in Abbildung 8 dargestellt, zeigt sich somit eine klare Dominanz des Maschinenbaus als primäres Tätigkeitsfeld, was der thematischen Ausrichtung der Untersuchung entspricht.

Gleichzeitig gewährleistet die Beteiligung angrenzender technischer Branchen und individueller Tätigkeitsfelder eine inhaltliche Breite, die Rückschlüsse auf übergreifende Anwendungspotenziale generativer KI im industriellen Kontext erlaubt.

Im Anschluss an die Erfassung der Branchenzugehörigkeit wurde die berufliche Rolle der Teilnehmenden analysiert, um die funktionale Einbindung der Befragten innerhalb ihrer Unternehmen zu beschreiben und potenzielle Unterschiede in der Perspektive auf den Einsatz generativer KI entlang verschiedener Aufgabenfelder zu identifizieren. Diese Variable dient der kontextuellen Einordnung der Ergebnisse im Hinblick auf die funktionale Nähe zu Entwicklungs-, Fertigungs- oder Managementprozessen im ingenieurtechnischen Umfeld.

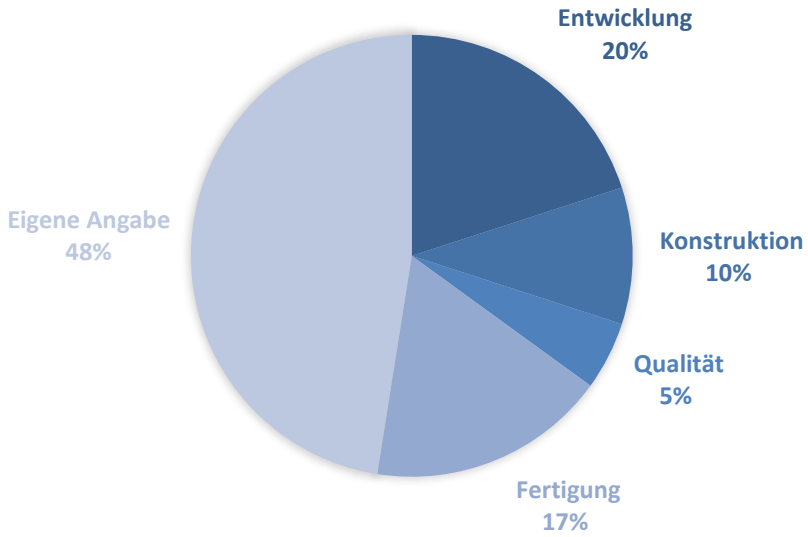


*Abbildung 9: Rollenverteilung der Stichprobe. Eigene Darstellung.*

Die Auswertung zeigt eine heterogene Verteilung der Rollen innerhalb der Stichprobe. Von den insgesamt $n = 40$ Befragten entfallen 20% auf den Bereich Entwicklung, 10% auf Konstruktion, 5% auf Qualitätssicherung sowie 17,5% auf den Bereich Fertigung. Den größten Anteil bildet die Kategorie der eigenen Angaben mit 47,5%, die vielfältige, teils interdisziplinäre Funktionsbezeichnung umfasst.

Ausgehend von der in der Ingenieurwissenschaft etablierten Unterscheidung zwischen taktischem und strategischem Ingenieurshandeln wurde die berufliche Rollenverteilung der Teilnehmenden analysiert. Während das taktische Ingenieurwesen auf die Lösung klar definierter technischer Aufgaben ausgerichtet ist, zielt das strategische Ingenieurwesen auf die Gestaltung neuer Ziele und Strukturen und betont Anpassungsfähigkeit sowie übergreifendes Denken. Diese Unterscheidung lässt sich auf die Tätigkeitsprofile der Befragten übertragen. Rollen mit direktem Bezug zu Entwicklung, Konstruktion, Qualitätssicherung und Fertigung spiegeln ein

eher taktisch-operatives Handeln wider, während Funktionen in Management, Prozessplanung oder Projektleitung strategische Aufgabenfelder repräsentieren. (Fukuda, 2019)

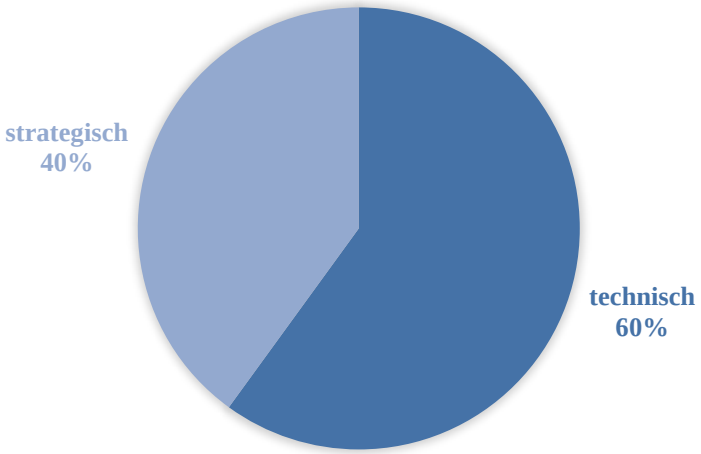


*Abbildung 10: Technisch - Strategische Unterscheidung der Rollen. Eigene Darstellung.*

Die Auswertung zeigt, dass 60% der Teilnehmenden technisch-operativen und damit taktischen Rollen zugeordnet werden können, während 40% in strategisch-prozessbezogenen Funktionen tätig sind. Diese Einteilung schafft eine theoretische Grundlage, um die weiteren Ergebnisse entlang funktionaler Perspektiven auf den Einsatz generativer KI im Maschinenbau zu interpretieren. Dennoch lässt sich auf einzelne Rollen zurückgreifen, um diese im Kontext des Einsatzes generativer KI vertieft zu betrachten.

Schließlich wurde im Rahmen der empirischen Untersuchung auch die Unternehmensgröße der Teilnehmenden Organisationen erhoben, um den strukturellen Hintergrund der Befragten zu charakterisieren.

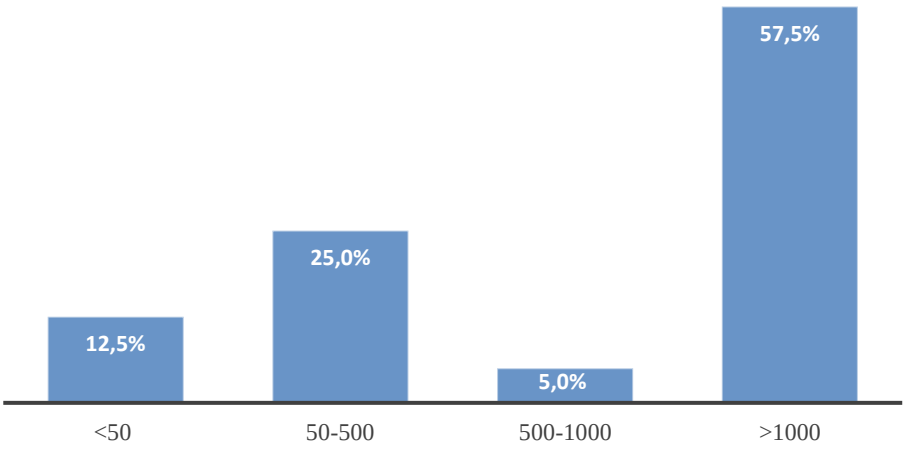


*Abbildung 11: Verteilung der Unternehmensgröße. Eigene Darstellung.*

Die Ergebnisse zeigen eine deutliche Dominanz großer Industrieunternehmen innerhalb der Stichprobe. Mit einem Anteil von 55% sind die meisten Teilnehmenden in Unternehmen mit mehr als 1000 Mitarbeitenden tätig. Kleine und mittlere Unternehmen mit 50 bis 500 Beschäftigen stellen mit 27,5% die zweitgrößte Gruppe dar, gefolgt von Kleinstunternehmen mit weniger als 50 Mitarbeitenden (12,5%) und mittleren Betrieben mit 500 bis 1000 Mitarbeitenden (5%). Wie in der Abbildung 11 zu sehen, zeigt der berechnete Median $M = 4$ und entspricht damit der Kategorie der Unternehmensgröße mit mehr als 1000 Mitarbeitenden.

Im Vergleich zur Struktur des deutschen Maschinenbaus, der überwiegend von kleinen und mittleren Betrieben geprägt ist, zeigt die Stichprobe eine überdurchschnittliche starke Repräsentation großer Industrieunternehmen. Während Großbetriebe mit über 1000 Mitarbeitenden in der Gesamtbranche nur einen geringen Anteil ausmachen, stellen sie in der vorliegenden Erhebung 55% der Befragten dar. (Statistisches Bundesamt, 2025) Diese Schwerpunktbildung könnte darauf hinweisen, dass größere Industrieunternehmen aufgrund ihrer strukturellen und technologischen Voraussetzung tendenziell stärker in den Einsatz generativer KI eingebunden sind. Es ist anzunehmen, dass insbesondere ihre ausgeprägteren Ressourcen, digitalen Infrastrukturen und Strategien, Innovationsprogramme den Zugang und die Nutzung entsprechender Technologien begünstigen.

Zusammenfassend zeigt die deskriptive Analyse, dass die Stichprobe überwiegend aus jüngeren Fachkräften im Alter von 25 und 29 Jahren besteht, die sich mehrheitlich in frühen beruflichen Erfahrungsphasen befinden. Die Teilnehmenden sind vorwiegend in Nordrhein-Westfalen tätig und größtenteils im klassischen Maschinenbau beschäftigt, wobei angrenzende technische

Branchen vertreten sind. In funktionaler Hinsicht überwiegen technische Rollen in Entwicklung, Konstruktion, Qualitätssicherung und Fertigung, während Management- und prozessbezogene Tätigkeiten einen kleineren, aber relevanten Anteil bilden. Zudem zeigt sich eine deutliche Dominanz großer Industrieunternehmen, was die strukturelle Einbettung der Befragten in forschungsintensive und technologisch geprägte Umgebungen widerspiegelt.

Diese Merkmale kennzeichnen die Stichprobe als überwiegend junge, technisch orientierte und industrienahe Zielgruppe, die ein repräsentatives Bild des Umfelds im Maschinenbau vermittelt. Auf dieser Grundlage erfolgt im folgenden Kapitel die inferenzstatische Analyse, in der geprüft wird, inwieweit sich zwischen den beschriebenen Personen- und Kontextmerkmalen sowie der Nutzung generativer KI systematische Zusammenhänge erkennen lassen.

## 7.2 Inferenzstatische Analyse

Im folgenden Kapitel werden die Ergebnisse der inferenzstatistischen Analyse dargestellt und interpretiert. Ziel ist es, über die rein deskriptive Beschreibung der Daten hinauszugehen und statistisch überprüfbare Aussagen über Zusammenhänge und Unterschiede zwischen den erhobenen Variablen zu treffen. Auf diese Weise werden, die im theoretischen Teil formulierten Hypothesen empirisch überprüft und mögliche Einflussfaktoren auf den Einsatz generativer KI im Maschinenbau identifiziert.

Ausgangspunkt der inferenzstatischen Betrachtung bildet der Themenblock „Nutzungsstatus & Häufigkeit“, der Aufschluss darüber gibt, in welchem Umfang und mit welcher Regelmäßigkeit generative KI von den Befragten im beruflichen Kontext eingesetzt wird.

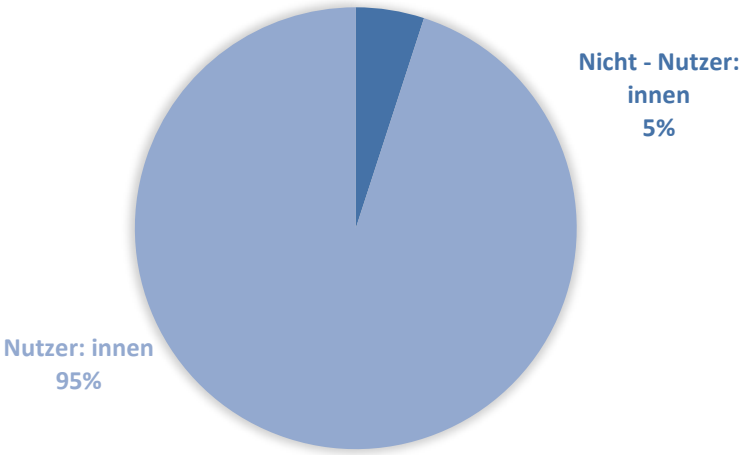


*Abbildung 12: Nutzungsstatus der Stichprobe. Eigene Darstellung.*

Innerhalb der Gesamtstichprobe von $n = 40$ konnten zwei Nicht-Nutzer: innen und 38 Nutzer: innen identifiziert werden. Damit zeigt sich, dass der überwiegende Teil der Teilnehmende bereits praktische Erfahrungen mit generativer KI gesammelt hat. Die geringe Zahl der Nicht-Nutzer: innen erlaubt demnach keine belastbaren inferenzstatistischen Vergleiche, weshalb diese Gruppe im Verlauf der Analyse nur deskriptiv und kontextuell berücksichtigt wird. Der analytische Schwerpunkt der Auswertung liegt somit auf der Gruppe der Nutzer: innen die mit 95% den Hauptteil der Stichprobe repräsentierten und eine aussagekräftige empirische Grundlage für die Analyse bilden. Die deskriptive Auswertung der Variable Nutzungsstatus lässt darauf deuten, dass die Mehrheit der Befragten generative KI regelmäßig in ihre Arbeitsprozesse integriert haben. Anhand der Variable Nutzungshäufigkeit lässt sich schließlich innerhalb der Teilstichprobe von $n = 38$ Nutzer: innen ermitteln, in welchem Ausmaß es sich um eine eher gelegentliche oder intensivere Anwendung generativer KI im beruflichen Kontext handelt. Die Variable verdeutlicht somit, in welchem Umfang generative KI von den befragten Personen innerhalb der letzten 30 Tage eingesetzt wurde.

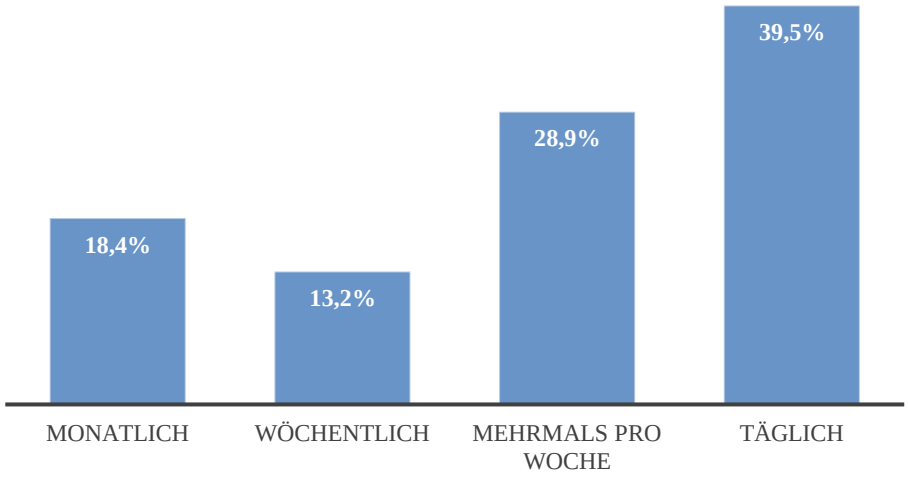


*Abbildung 13: Nutzungshäufigkeit. Eigene Darstellung.*

Die Ergebnisse der Untersuchung zeigen, dass 7 Personen (18,4 %) generative KI monatlich verwenden, 5 Personen (13,2 %) wöchentlich, 11 Personen (28,9 %) mehrmals pro Woche und 15 Personen (39,5 %) täglich. Diese Verteilung weist auf eine deutliche Schwerpunktbildung in den höheren Nutzungskategorien hin und unterstreicht die zunehmende Integration generativer KI im beruflichen Alltag. Zur quantitativen Abbildung der Nutzung wurde den einzelnen Kategorien eine numerische Zuordnung zugewiesen, die die geschätzte Anzahl an Nutzungsta-

gen im Zeitraum von 30 Tagen repräsentiert. Auf dieser Grundlage ergibt sich ein arithmetischer Mittelwert von $M = 14{,}2$ Nutzungstagen innerhalb des Betrachtungszeitraums, was einer durchschnittlichen Anwendung alle zwei bis drei Tage entspricht. Daraus lässt sich ableiten, dass generative KI nicht nur von der überwiegenden Mehrheit der Befragten eingesetzt wird, sondern auch regelmäßig und in einem hohen Maß in bestehende Arbeitsprozesse eingebunden ist. Hinsichtlich der bereits in der deskriptiven Statistik dargestellten Verteilung der Unternehmensgrößenklassen der Stichprobe sowie der zuvor beschriebenen Nutzungshäufigkeit kann nun die theoretisch hergeleitete Hypothese zum Zusammenhang zwischen Unternehmensgröße und Nutzungshäufigkeit (siehe Kapitel 5.1.1.) inferenzstatistisch überprüft werden. Diese Hypothese geht davon aus, dass mit zunehmender Unternehmensgröße auch die Nutzungshäufigkeit generativer KI ansteigt.

Zur Prüfung dieser Hypothese wurde die Spearman-Rangkorrelation berechnet, um die Stärke und Richtung der Beziehung zwischen den beiden ordinal skalierten Variablen Unternehmensgröße und Nutzungshäufigkeit zu bestimmen. Dieses Verfahren eignet sich insbesondere für nicht normalverteilte sowie ordinal skalierte Daten, da es auf der Rangordnung der Werte basiert und monotone Zusammenhänge identifiziert, ohne lineare Verteilungsannahmen vorauszusetzen. (Bortz & Schuster, 2010; Moosbrugger & Kelava, 2012)

Die Berechnung ergab einen Korrelationskoeffizienten von $\rho = -0{,}024$ bei einem p-Wert von 0,89. Damit liegt kein statistisch signifikanter Zusammenhang zwischen der Unternehmensgröße und der Nutzungshäufigkeit generativer KI vor. Folglich konnte die in der Hypothese formulierte Annahme eines positiven Zusammenhangs nicht bestätigt werden, womit die Nullhypothese greift, die von einem fehlenden signifikanten Zusammenhang zwischen beiden Variablen ausgeht. Nach der inferenzstatistischen Logik bedeutet ein derart geringer Korrelationswert in Verbindung mit einem hohen p-Wert, dass das beobachtete Ergebnis mit sehr hoher Wahrscheinlichkeit zufällig zustande gekommen ist und somit kein systematischer Zusammenhang zwischen den Variablen besteht. (Bortz & Schuster, 2019; Moosbrugger & Kelava, 2012)

Das Ergebnis zeigt, dass die Unternehmensgröße keinen messbaren Einfluss auf die Intensität der Nutzung generativer KI hat. Diese empirische Beobachtung deutet darauf hin, dass der Einsatz generativer KI im Maschinenbau nicht primär von strukturellen Faktoren wie der Unternehmensgröße abhängt, sondern über verschiedene Größenklassen hinweg weitgehend gleichmäßig erfolgt. Stattdessen scheint die Nutzung stärker durch individuelle Merkmale, funktionale Aufgabenbereiche und spezifische Anwendungsbedarfe geprägt zu sein. Insgesamt lässt

sich daraus schließen, dass generative KI im industriellen Umfeld bereits übergreifend etabliert ist und unabhängig von der Unternehmensgröße Anwendung findet.

Daraus ergibt sich das Interesse, die konkreten Einsatzfelder generativer KI innerhalb der industriellen Wertschöpfung genauer zu untersuchen. Im folgenden Abschnitt werden daher die Ergebnisse des Themenblocks „Einsatzfelder generativer KI“ dargestellt. Sie geben Aufschluss darüber, in welchen Anwendungsbereichen und Funktionskontexten generative KI derzeit eingesetzt wird und ermöglichen damit ein differenziertes Bild ihrer praktischen Integration in die Arbeitsprozesse der Befragten. Aufbauend auf dem im Kapitel zum Forschungsdesign beschriebenen Variablenkonzept wurde in der empirischen Untersuchung zunächst die Funktionssicht erfasst. Die Erhebung umfasst neun zentrale Tätigkeitsfelder des Ingenieurwesens, die typische Aufgaben- und Verantwortungsbereiche in der industriellen Praxis abbilden. Ziel der Analyse war es, die funktionalen Einsatzbereiche generativer KI zu identifizieren und zu bestimmen, in welchen Tätigkeiten ihre technischen Potenziale derzeit besonders stark zum Tragen kommen. Auf dieser Grundlage lässt sich erkennen, in welchen Segmenten der industriellen Wertschöpfung generative KI bereits eine messbare Rolle spielt und wo sich ihr Anwendungspotenzial gegenwärtig am deutlichsten sichtbar macht.

Die Auswertung der empirischen Daten (n = 38) verdeutlicht, in welchen funktionalen Tätigkeitsfeldern generative KI gegenwärtig am häufigsten eingesetzt wird. Auf Basis der erhobenen Nutzungsangaben wurde eine Rangordnung der neun definierten Tätigkeitsbereiche erstellt, um die relative Bedeutung und Verbreitung generativer KI innerhalb der unterschiedlichen Funktionsfelder des Ingenieurwesens analytisch abzubilden.

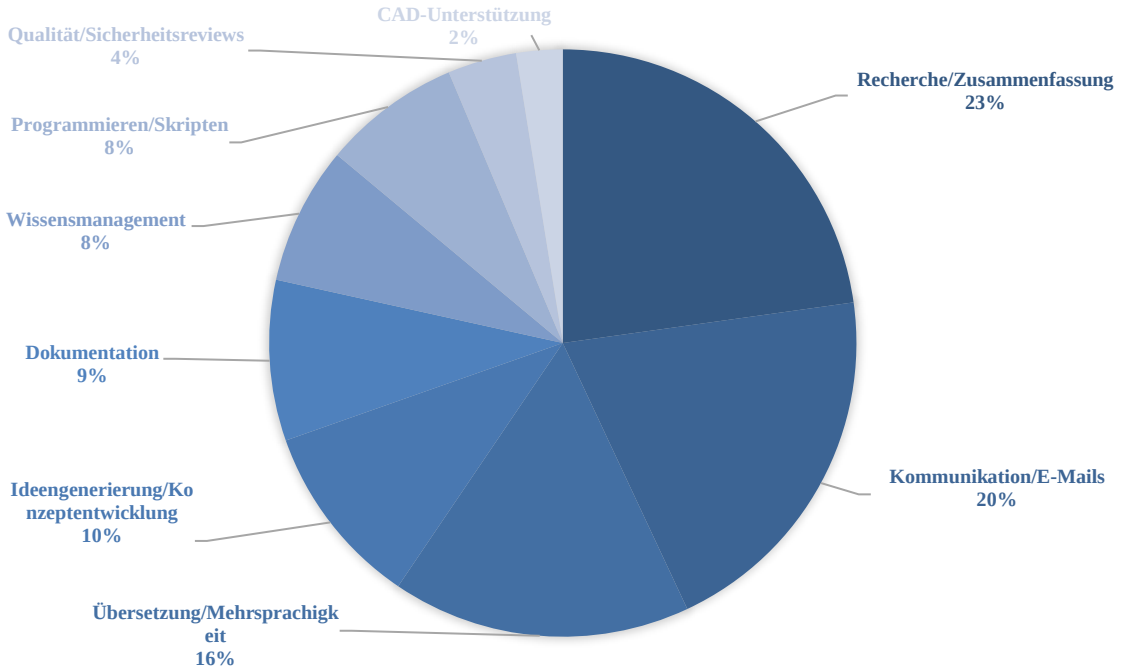


*Abbildung 14: Relative Häufigkeitsverteilung der einzelnen Einsatzfelder. Eigene Darstellung*

Wie in Abbildung 14 dargestellt, ergab sich aus den Antworten der Teilnehmenden eine klare Rangfolge der Tätigkeitsfelder. Den ersten Platz nimmt der Bereich *Recherche und Zusammenfassung* ein, gefolgt von *Kommunikation und E-Mails* auf dem zweiten sowie *Übersetzung und Mehrsprachigkeit* auf dem dritten Rang. Damit zeigt sich eine deutliche Konzentration auf wissensbezogene, textuelle und kommunikative Aufgabenfelder, in denen der größte praktische Nutzen generativer KI im Arbeitskontext verortet wird.

Diese Verteilung lässt sich im historischen und technologischen Kontext der Einführung generativer Sprachmodelle einordnen. Mit der Veröffentlichung von ChatGPT im November 2022 begann eine neue Ära generativer KI, in der erstmals ein leistungsfähiges Sprachmodell einer breiten Öffentlichkeit frei zugänglich war. Durch diese Entwicklung wurde der Einsatz generativer KI-Systeme insbesondere in textintensiven und wissensbasierten Tätigkeiten stark gefördert. Die benutzerfreundliche Oberfläche und der niederschwellige Zugang ermöglichten es, ohne komplexe Systemintegrationen oder spezielle Fachkenntnisse Aufgaben wie Recherche, Informationsaufbereitung und Textzusammenfassung effizient zu bearbeiten. Diese Verfügbarkeit führte zu einer breiten Anwendung solcher Systeme, die als gesellschaftlicher Einstiegspunkt generativer KI gilt. (Picazo-Sanchez et al., 2024) Große Sprachmodelle wie die Large Language Models (LLMs) sind besonders geeignet für wissens- und textintensive Aufgaben,

da sie umfangreiche Dokumente strukturieren, Kernaussagen extrahieren und abstraktive Zusammenfassungen erstellen können (Zhang). Genau diese Fähigkeiten erklären, warum Tätigkeiten der Informationsbeschaffung, Verdichtung und Wissensorganisation den Ausgangspunkt der praktischen Nutzung generativer KI bilden. Sie ermöglichen eine spürbare Effizienzsteigerung und machen die Technologie zu einem alltäglichen, kognitiv unterstützenden Werkzeug im industriellen Arbeitskontext. (Picazo-Sanchez et al., 2024) Diese Entwicklung lässt sich auch auf das ingenieurtechnische Arbeitsumfeld übertragen, das in hohem Maße durch dokumenten- und datenbasierte Wissensarbeit geprägt ist. Die Nutzung generativer KI in diesen Tätigkeitsbereichen führt zu einer unmittelbaren Entlastung und Effizienzsteigerung bei der Bearbeitung technischer Texte, Berichte und Informationsquellen. Die dynamische Verbreitung von ChatGPT im öffentlichen Raum hat somit auch die Adaption solcher Systeme in technischen Berufen begünstigt. Dies spiegelt sich auch in den Ergebnissen zur Tool-Breite der empirischen Untersuchung wider. Von den insgesamt 38 Nutzer: innen gaben 33 Personen an, Chat GPT als primäres generatives KI-Werkzeug zu verwenden.

Die Ausprägungen der Nutzung generativer KI zeigen sich auch in sprachlich-kommunikativen Tätigkeiten, insbesondere in Bereichen der textbasierten Kommunikation. Aufgaben wie das Verfassen, Korrigieren und Strukturieren von E-Mails stellen wiederkehrende, sprachlich standardisierte Tätigkeiten dar, die sich durch KI-gestützte Systeme effizient automatisieren und qualitativ verbessern lassen. Darüber hinaus lässt sich aus den Ergebnissen ableiten, dass generative KI auch im Bereich der Übersetzung und Mehrsprachigkeit eine zunehmend wichtige Rolle spielt. Nutzer: innen profitieren beispielsweise von der Möglichkeit, fremdsprachige Fachartikel besser zu verstehen oder E-Mails automatisch in andere Sprachen zu übertragen, was insbesondere in international agierenden Unternehmen von Vorteil ist. Diese sprachübergreifende Unterstützung, die direkt aus den textverarbeitenden Fähigkeiten generativer KI hervorgeht, erklärt, warum sich diese drei Einsatzfelder in der Rangordnung der Nutzung auf den ersten drei Plätzen wiederfinden und zu den häufigsten Einsatzfeldern generativer KI zählen.

Die aufgezeigte Rangordnung wird, durch die in der empirischen Untersuchung erhobenen anonymisierten Kurzbeispiele bekräftigt. In einem Freitextfeld wurden die Teilnehmenden gebeten, einen für sie typischen Einsatz generativer KI in ihrem Arbeitskontext zu beschreiben. Die qualitative Auswertung dieser Angaben verdeutlicht eindrücklich, dass sich der praktische Einsatz generativer KI in der beruflichen Realität der Befragten überwiegend in jenen Tätigkeitsfeldern wiederfindet, die auch in der Rangordnung der Funktionssicht die vorderen Plätze ein-

nahmen. In rund 80 % der erhobenen Kurzbeispiele lassen sich die beschriebenen Anwendungen eindeutig den Bereichen *Recherche und Zusammenfassung, Kommunikation und E-Mails* sowie *Übersetzung und Mehrsprachigkeit* zuordnen.

Die Aussagen der Befragten zeigen, dass generative KI vor allem dort genutzt wird, wo sprachliche Ausdrucksfähigkeit, Textstrukturierung und Informationsverdichtung gefragt sind. So beschreibt eine teilnehmende Person beispielsweise den „*Einsatz von KI, um E-Mails professionell zu schreiben"*, während eine andere angibt, die Technologie *„grundsätzlich oft für E-Mails und Formulierungen in der Arbeit*" zu verwenden. Diese Beispiele machen deutlich, dass generative KI insbesondere in kommunikativen Routineaufgaben eingesetzt wird, um Formulierungen zu präzisieren und die Qualität zu verbessern. Darüber hinaus wird erkennbar, dass auch der Bereich der Informationsverarbeitung und Wissenserschließung eine zentrale Rolle spielt. So berichten Nutzer: innen, sie würden generative KI verwenden, um *„Dokumente nach Kernaussagen zu untersuchen"* oder sie als *„Sparringpartner bei der Recherche über ein gewisses Thema – begleitendes Lernen"* einzusetzen. Diese Beispiele verdeutlichen, dass generative KI nicht nur als Werkzeug zur Automatisierung, sondern zunehmend als intelligente Assistenz im kognitiven Arbeitsprozess verstanden wird, dass die Informationssuche unterstützt, Zusammenhänge verdichtet und Lernprozesse begleitet. Neben der arbeitsunterstützenden Nutzung generativer KI betonen einige Befragte auch deren Beitrag zur Ideenfindung und kreativen Inspiration („*Erhöht die Kreativität*") als relevantes Einsatzfeld im Arbeitskontext. Besonders in den frühen Phasen kreativer Prozesse kann der Einsatz generativer KI die Ideenentwicklung und Exploration fördern, indem sie alternative Perspektiven und neuartige Vorschläge bereitstellt. Kreativität wird dabei zunehmend als Ergebnis einer kooperativen Interaktion zwischen Mensch und Maschine verstanden, die zu einer Erweiterung des kreativen Handlungsspielraums führt (Heigl, 2025).

Einen kreativen Charakter besitzt auch der Dokumentationsprozess sowie das daraus entstehende Wissensmanagement, das als systematischer Prozess zur Identifikation, Erfassung, Strukturierung, Speicherung und Verteilung von Wissen innerhalb einer Organisation verstanden wird (Probst et al., 2012). Im ingenieurtechnischen Umfeld ist dieser Prozess eng mit der Dokumentation und Protokollierung technischer Tätigkeiten verbunden, da hierdurch Erfahrungs- und Entwicklungswissen bewahrt und für zukünftige Produktzyklen nutzbar gemacht wird (Probst et al., 2012). Die Relevanz dieser Tätigkeiten zeigt sich auch in der Nutzungsintensität generativer KI, bei der die Einsatzfelder *Dokumentation und Protokollierung* und *Wissensmanagement* eine nahezu identische Rangordnung aufweisen. Dies verdeutlicht, dass die

Nutzung generativer KI in diesen Bereichen als unterstützend und entlastend wahrgenommen wird. Ein: e Teilnehmende: r beschreibt den Einsatz generativer KI mit der Aussage *„Wie baue ich eine technische Dokumentation am besten auf?“* was den Mehrwert der Technologie in der Strukturierung und sprachlichen Aufbereitung technischer Inhalte veranschaulicht.

Durch ihre Fähigkeit, unstrukturierte Informationen in konsistente Textformen zu überführen, standardisierte Dokumentationsmuster vorzuschlagen und inhaltliche Zusammenhänge im Wissensbestand zu erkennen, entsteht ein erheblicher Nutzen für die Dokumentationspraxis im Ingenieurwesen. Damit fungiert generative KI nicht nur als Werkzeug zur Effizienzsteigerung, sondern auch als kognitiver Partner, der die kreative und analytische Aufbereitung technischer Inhalte unterstützt. Insgesamt lässt sich ein erkennbarer Trend in der Rangordnung identifizieren, der auf ein Adoptionsmuster entlang der Dimensionen Aufgabenkomplexität, Verantwortungsrisiko und Verifizierbarkeit hinweist. Generative KI wird zunächst besonders intensiv dort eingesetzt, wo sprachliche und textuelle Transformationen sowie kreative Exploration dominieren. In diesen Bereichen kann die Technologie den kreativen Handlungsspielraum nachweislich durch Variantenbildung, Inspiration und die schnelle Rekombination bestehenden Wissens erweitern. Gleichzeitig bleibt die menschliche Steuerung weiterhin zentral.

Im Einsatzfeld der Programmierung und Skripterstellung, das in der Rangordnung den siebten Platz einnimmt, zeigt sich mit einem Anteil von knapp 16 % zwar eine geringere, jedoch weiterhin beachtliche Nutzungsintensität generativer KI. Dies lässt sich vor allem dadurch erklären, dass Programmieraufgaben stark branchenspezifisch ausgeprägt sind. Gleichwohl belegen aktuelle Untersuchungen, dass sich die Programmierung aufgrund ihrer textbasierten und regelgeleiteten Struktur besonders für den Einsatz generativer KI eignet. Generative Modelle zeigen im softwaretechnischen Kontext insbesondere bei der Code-Generierung, der Fehlersuche und der Optimierung deutliche Effizienzsteigerungen. Generative KI wird dabei zunehmend, als kollaborativer Partner verstanden, der die Reflexion und Verbesserung des Programmierstils unterstützt und damit über reine Automatisierung hinaus einen qualitativen Mehrwert schafft. (Bahn et al., 2025)

Mit Blick auf die weiteren Einsatzfelder setzt sich der abnehmende Trend der Nutzungsintensität fort. In den Bereichen Qualitäts- und Sicherheitsreviews (7,9 %) sowie CAD- und CAE-Unterstützung (5,3 %) nimmt die Anwendung generativer KI deutlich ab. Diese Entwicklung lässt sich durch die zunehmende Komplexität, die Verantwortungsrelevanz und die erforderliche Verifizierbarkeit dieser Aufgaben erklären.

Im Bereich der CAD-Unterstützung werden die bestehenden Hürden auch in der wissenschaftlichen Literatur hervorgehoben. Tätigkeiten in diesem Feld erfordern präzise geometrische, numerische und physikalische Modelle, die weit über die primär sprachbasierten Fähigkeiten generativer Systeme hinausgehen. Diese Diskrepanz spiegelt sich in den in der Literatur beschriebenen technologischen Einschränkungen der verfügbaren Trainingsdatensätze wider. Zwar existieren verschiedene öffentliche CAD-Datensätze, diese weisen jedoch erhebliche Limitationen hinsichtlich struktureller Komplexität, Detailgrad und Repräsentativität auf. (Berger et al., 2025) Aktuelle Entwicklungen deuten allerdings darauf hin, dass sich diese Engpässe durch neue methodische Ansätze zunehmend überwinden lassen. So kann beispielsweise durch den Einsatz von LoRA-Fine-Tuning der Trainingsaufwand konkretisiert und erheblich reduziert werden. In diesem Anwendungsbeispiel wurde ein Modell gezielt mit Datensätzen aus dem Felgendesign vortrainiert, um anschließend auf Basis der generierenden Konstruktionsdaten funktional und strukturell valide CAD-Designs zu erzeugen (Li et al., 2025).

Dennoch zeigen aktuelle Forschungsarbeiten, dass der Einsatz generativer KI in diesen technisch anspruchsvollen Anwendungsfeldern bislang überwiegend explorativ und konzeptionell geprägt ist. Aus der empirischen Untersuchung geht hervor, dass rund 60 % der Befragten in technisch-operativen Tätigkeiten tätig sind, wobei etwa 13 % eindeutig dem Bereich der Konstruktion zugeordnet werden können. Die erfasste Tool-Breite verdeutlicht zudem, dass die derzeit verwendeten KI-Werkzeuge überwiegend auf sprachbasierten Modellen beruhen. Diese Fokussierung erklärt, die in der Untersuchung beobachtete, Rangordnung sowie die bislang geringe Integration generativer KI in technisch anspruchsvollen Arbeitsfeldern, die höhere Anforderungen an Präzision und domänenspezifisches Fachwissen stellen. Insgesamt lässt sich daraus ableiten, dass sich der Einsatz generativer KI vorwiegend in Anwendungsfeldern wiederfindet, die auf sprachliche Transformation, Wissensrekombination und kreative Exploration ausgerichtet sind.

Aus den vorliegenden Erkenntnissen lässt sich ableiten, welche Aufgaben und Funktionen generative KI im Arbeitskontext übernimmt. Im Hinblick auf den Produktentstehungsprozess (PEP) wird deutlich, dass sich die identifizierten Einsatzfelder und Funktionsbereiche phasenübergreifend verorten lassen. Bereits in der Hypothesenentwicklung wurde angenommen, dass der wesentliche Nutzen generativer KI insbesondere in der Anregung kreativer Prozesse sowie in der Erhöhung der Variantenvielfalt liegt. In den frühen Phasen des Produktentstehungsprozesses entfaltet generative KI ihre Stärken vor allem durch die Fähigkeit, komplexe Informationen zu verknüpfen und daraus neuartige Lösungsansätze zu generieren.

Vor diesem Hintergrund wurde die Annahme formuliert, dass Ingenieur: innen generative KI vornehmlich in den frühen Phasen des Produktentstehungsprozesses, also in der Produktplanung und Konzeptentwicklung, einsetzen. Zur Überprüfung dieser Hypothese wurde untersucht, in welchen Phasen des Produktentstehungsprozesses der tatsächliche Einsatz generativer KI erfolgt. Wie im Kapitel zum Forschungsdesign beschrieben, wurde dieser Aspekt im Rahmen der Prozesssicht operationalisiert. Die Teilnehmenden gaben dabei an, in welchen Entwicklungsphasen sie generative KI in ihrer beruflichen Praxis nutzen. Um die Bandbreite der Anwendung entlang des gesamten Entwicklungsprozesses differenziert abzubilden, konnten mehrere Phasen parallel ausgewählt werden.

Diese Vorgehensweise erlaubt eine differenzierte Betrachtung der Nutzung generativer KI entlang der Phasen des Produktentstehungsprozesses.

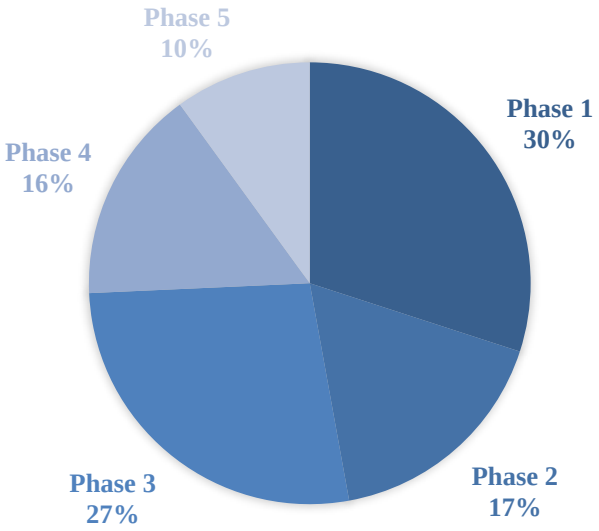


*Abbildung 15: Phasenverteilung des Einsatzes generativer KI im PEP. Eigene Darstellung.*

Die deskriptive Auswertung der erhobenen Daten zeigt, dass der Einsatz generativer KI mit einem Anteil von rund 30 % am häufigsten in der Phase 1 der Produktplanung erfolgt, wie in der Abbildung 15 zu sehen ist. Dieses Ergebnis stützt die formulierte Hypothese, wonach der Nutzungsschwerpunkt generativer KI in den frühen Phasen des Produktentstehungsprozesses liegt.

Bemerkenswert ist zudem, dass auch die Phase der Arbeitsvorbereitung mit einem Anteil von 27,14 % eine vergleichsweise hohe Relevanz aufweist, was auf eine zunehmende operative Einbindung generativer KI in vorbereitende und unterstützende Tätigkeiten hindeutet. Die Arbeitsvorbereitung als vorgelagerte Phase der Produktion umfasst typischerweise Aufgaben wie

die Materialauswahl, die Planung der Fertigung sowie die Entwicklung einzelner Arbeitsabläufe. Anhand der beruflichen Rollen der Befragten lässt sich erkennen, dass sowohl durch den jeweiligen Arbeitskontext als auch durch die persönliche Tätigkeit eine inhaltliche Verortung in dieser Phase vorgenommen wurde. Die detaillierte Sichtung der erhobenen Datensätze bestätigt diese Einordnung. So beschreibt beispielsweise eine teilnehmende Person in den anonymisierten Kurzbeispielen zur Nutzung generativer KI die Anwendung eines KI-Modells zur *„Abfrage von verschiedenen Werkstoffen“*. Dabei handelt es sich um eine Form der Informationsrecherche, bei der generative KI zur Ermittlung geeigneter Materialien im jeweiligen Arbeitsszenario eingesetzt wird. Ebenso verdeutlicht das Beispiel der beruflichen Rolle des Verfahrenstechniker: innen den Einsatz generative KI-Modelle, um den *„Stand der Technik für bestimmte Prozessverfahren“* zu ermitteln. Dies lässt auf den Aufgabenbereich der Arbeitsvorbereitung hindeuten. In beiden Fällen kommen die bereits in den vorherigen Abschnitten beschriebenen Funktionsbereiche generativer KI zum Tragen, insbesondere die Recherche, Zusammenfassung und Dokumentation von Wissen sowie die kreative Interaktion zwischen Mensch und KI zur Generierung neuer Lösungsansätze oder zur Identifikation von Optimierungspotenzialen. Diese Beispiele verdeutlichen zugleich das phasenübergreifende Auftreten solcher Tätigkeiten entlang des Produktentstehungsprozesses, bei denen sich die funktionalen Anwendungsmuster generativer KI über verschiedene Entwicklungsstufen hinweg wiederfinden. Das Beispiel der Werkstoffabfrage repräsentiert ein typisches Nutzungsszenario, das der Detailplanung unmittelbar vorgelagert ist. Ebenso verweist die Einholung des Standes der Technik für bestimmte Prozessverfahren direkt auf die Arbeitsvorbereitung, in der Verfahrens- und Materialentscheidungen getroffen werden, die anschließend in Arbeitspläne, Fertigungsroutinen und technische Anweisungen überführt werden.

Beide Rollen verdeutlichen exemplarisch, dass generative KI sowohl vor als auch innerhalb und teilweise als Bestandteil der Arbeitsvorbereitung von den Befragten interpretiert und genutzt wird. Dabei handelt es sich jedoch nicht um komplexe, domänenspezifisch trainierte KI-Systeme, sondern überwiegend um die Nutzung generischer Sprachmodelle, die zur Wissensrecherche, zur Erweiterung des fachlichen Verständnisses und zur Unterstützung kreativer Problemlösungsprozesse im Arbeitskontext beitragen. Vor dem Hintergrund dieser Nutzungsmuster, die den zentralen Anwendungszeck generativer KI in der Gesamtstichprobe widerspiegeln, zeigt sich demnach auch der höchste Anteil in der Phase 1 der Produktplanung wieder. In diesen frühen Entwicklungsabschnitten entfalten insbesondere Large Language Models ihren größten Mehrwert, das sie ideenorientiere und wissensbasierte Aufgaben effektiv unterstützen.

Im weiteren Verlauf der Analyse richtet sich der analytische Fokus nun auf die Kenntnisebene der Befragten. Der individuelle Kenntnisstand stellt eine zentrale Einflussgröße dar, um die beobachteten Nutzungsmuster generativer KI zu verstehen und zu erklären. Denn ob und in welchem Umfang generative KI im beruflichen Kontext eingesetzt wird, hängt maßgeblich davon ab, wie kompetent und sicher Anwender: innen ihre eigenen Fähigkeiten im Umgang mit dieser Technologie einschätzen.

Die in der empirischen Untersuchung erhobene Variable des subjektiven Kenntnisstands beschreibt die Selbsteinschätzung der Befragten hinsichtlich ihres wahrgenommenen Wissens, ihrer Erfahrung sowie ihrer Anwendungskompetenz im Umgang mit generativer KI. Sie bildet damit eine erklärende Ebene für den Ist-Zustand der Nutzung, da sie Aufschluss darüber gibt, in welchem Maße die Wahrnehmung der eigenen Kompetenz die tatsächliche Anwendung generativer KI beeinflusst. Aufbauend auf der zuvor hergeleiteten theoretischen Annahme aus dem Kapitel zur Hypothesenentwicklung wird nun die Hypothese geprüft, dass ein höherer subjektiver Kenntnisstand von Ingenieur: innen mit einer höheren Nutzungshäufigkeit generativer KI einhergeht. Zur Überprüfung dieser Annahme wurde der subjektive Kenntnisstand in Form eines Kompetenz-Scores erfasst, der aus der Mittelwertbildung von sechs Selbsteinschätzungsitems auf einer fünfstufigen Likert-Skala berechnet wurde. Die Nutzungshäufigkeit wurde als unabhängige Variable operationalisiert und ebenfalls auf einer ordinalen Skala erfasst, um die Intensität der Nutzung im beruflichen Kontext zu quantifizieren. Zur statistischen Überprüfung der Annahme wurde eine Pearson-Korrelationsanalyse durchgeführt, die den linearen Zusammenhang zwischen beiden Variablen untersucht. Die Analyse ergab einen positiven Korrelationskoeffizienten von $r = 0{,}26$ bei einem Signifikanzniveau von $p = 0{,}05$.

Die Ergebnisse deuten auf einen tendenziell signifikanten positiven Zusammenhang zwischen dem wahrgenommenen Kompetenzempfinden und der tatsächlichen Nutzungshäufigkeit generativer KI hin. Ingenieur: innen, die ihre Kompetenz im Umgang mit generativer KI höher einschätzen, nutzen die Technologie im beruflichen Alltag entsprechend häufiger. Auch wenn der beobachtete Effekt in seiner Stärke nur moderat ausfällt, bestätigt das Ergebnis die theoretisch hergeleitete Annahme eines positiven Einflusses des subjektiven Kenntnisstands auf die Nutzungshäufigkeit und stützt damit die Hypothese H1.

Obwohl die Analyse einen positiven und signifikanten Zusammenhang zwischen dem subjektiven Kenntnisstand und der Nutzungshäufigkeit generativer KI bestätigt, ist die Stärke des Effekts als moderat einzustufen. Diese Ausprägung lässt sich auf Grundlage, der in den vorangegangenen empirischen Ergebnissen beschriebenen Nutzungsmuster erklären.

Die Untersuchung zeigte, dass der Einsatz generativer KI im Maschinenbau derzeit vor allem in sprachbasierten und kognitiven Aufgabenfeldern erfolgt, etwa in den Bereichen Recherche, Dokumentation, Textaufbereitung und teils der Ideengenerierung. Diese Tätigkeiten erfordern ein vergleichsweise geringes Maß an technischem Fachwissen, wodurch auch Personen mit niedrigerem subjektivem Kenntnisstand in der Lage sind, generative KI effizient anzuwenden. Folglich fällt der Zusammenhang zwischen Selbsteinschätzung der Kompetenz und tatsächlicher Nutzungshäufigkeit weniger stark aus, da die Nutzung nicht ausschließlich von technischem Wissen, sondern auch von Aufgabencharakter und Anwendungskontext bestimmt wird. Zum anderen zeigt sich, dass generative KI bislang nur begrenzt in komplexe ingenieurtechnische Prozesse wie Konstruktion, Simulation oder Fertigungsplanung integriert ist. In diesen Tätigkeitsfeldern wären höhere fachliche Kompetenzen und ein vertieftes Verständnis der Funktionsweise generativer KI erforderlich, um deren Einsatz wirksam zu gestalten.

Um die Analyse der Kenntnisebene zu vertiefen und ein umfassenderes Verständnis des Kompetenzprofils der Befragten zu gewinnen, wurde ergänzend der objektive Kenntnisstand erhoben. Dieser bildet eine inhaltliche Stütze zur Bewertung der zuvor dargestellten Selbsteinschätzung und ermöglicht es, Unterschiede zwischen wahrgenommener und tatsächlicher Kompetenz empirisch zu erfassen. Der objektive Kenntnisstand wurde in der Erhebung über gezielte Aussagen zum Fachwissen über Künstliche Intelligenz ermittelt, die indirekt abgefragt wurden, um kognitive Verzerrungen oder Prüfungsdruck zu vermeiden. Wie im Kapitel zum Forschungsdesign beschrieben, kam hierfür ein dreistufiges Likert-System zum Einsatz, mit dem die Zustimmung oder Ablehnung zu den formulierten Aussagen erfasst wurde. Jede Aussage besaß einen festgelegten Wahrheitswert, wodurch das tatsächliche Wissen der Teilnehmenden objektiv bewertet werden konnte. Aus den Antworten wurde ein Quiz-Score gebildet, der den Anteil korrekt beantworteter Items widerspiegelt und damit das tatsächlich überprüfbare Fachwissen zur Künstlichen Intelligenz quantifiziert. In der gesamten Stichprobe zeigte sich ein durchschnittlicher Anteil richtig beantworteter Aussagen von 37,5 %. Dieses Ergebnis verdeutlicht, dass das tatsächlich vorhandene Wissen über KI im Vergleich zur subjektiven Selbsteinschätzung (46%) deutlich geringer ausgeprägt ist, was auf eine Diskrepanz zwischen wahrgenommener und realer Kompetenz hinweist.

Zur Verdeutlichung der Diskrepanz zwischen wahrgenommenem und tatsächlichem Wissen wurde ergänzend eine Kalibrierungsanalyse durchgeführt. Hierzu wurden der subjektive Kennt-

nisindex und der objektive Quiz-Score normiert, und ihre Differenz als Kalibrierungslücke berechnet. Auf dieser Grundlage ließ sich die Stichprobe in vier Gruppen differenzieren, die das Verhältnis zwischen Selbstwahrnehmung und realem Wissen abbilden.

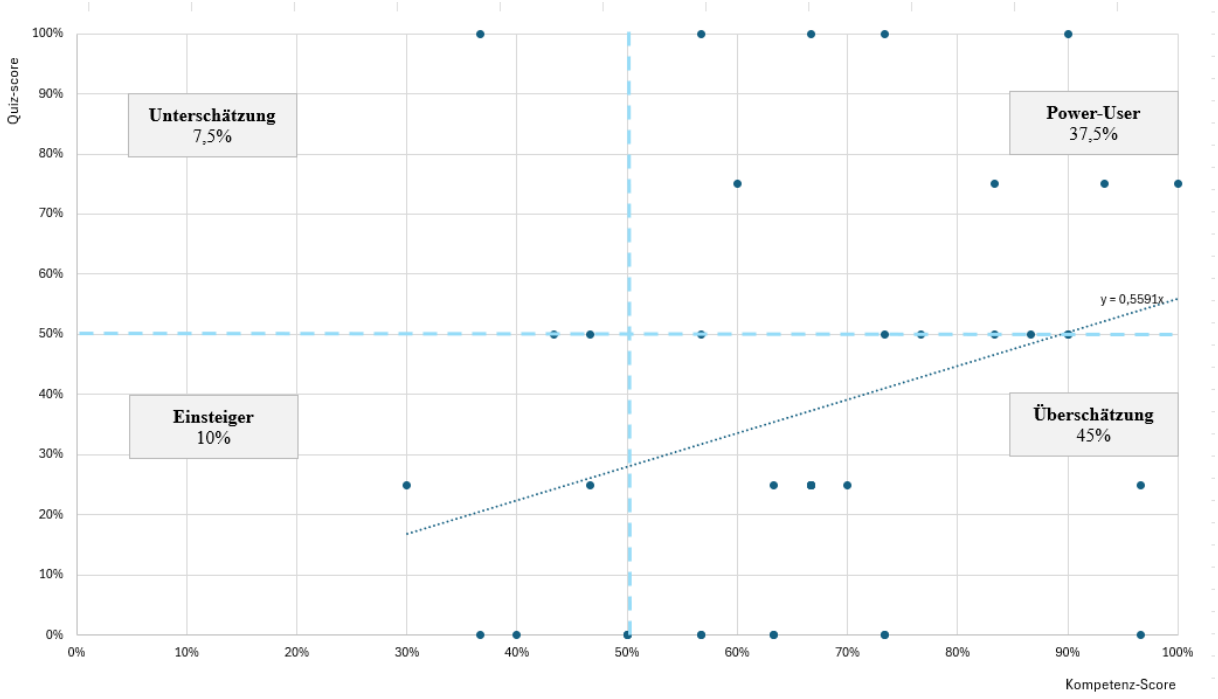


*Abbildung 16: Kalibrierungslücke (Quizscore / Kompetenzscore). Eigene Darstellung.*

Die Ergebnisse zeigen, dass 45 % der Befragten eine Überschätzung ihrer Kompetenz aufweisen, das heißt, ihr subjektiver Kenntnisstand liegt deutlich über dem tatsächlichen Wissen. Diese Gruppe lässt sich als Risikoprofil interpretieren, da sie generative KI mit hohem Vertrauen, aber geringem Fachverständnis nutzt. Etwa 37,5 % der Befragten können als Power-User klassifiziert werden. Sie verfügen sowohl über ein überdurchschnittliches Wissen als auch über eine realistische Selbsteinschätzung und nutzen generative KI entsprechend zielgerichtet. Eine kleinere Gruppe von 10 % zeigt sowohl einen geringen subjektiven als auch objektiven Kenntnisstand und ist somit als Einsteiger: innen zu identifizieren. Lediglich 7,5 % der Befragten unterschätzen ihr Wissen, indem sie ihre Fähigkeiten niedriger einschätzen, als sie tatsächlich sind. Die Regressionssteigung von y = 0,559 zeigt, dass zwischen subjektivem und objektivem Kenntnisstand ein positiver, jedoch abgeschwächter Zusammenhang besteht. Der Anstieg der objektiven Werte gegenüber den Selbsteinschätzungen weist schließlich auf eine tendenzielle Überschätzung der eigenen Kompetenz hin und verdeutlicht eine unvollständige Kalibrierung der Selbstwahrnehmung. Im Kontext der empirischen Ergebnisse verdeutlicht die Analyse, dass die hohe Verfügbarkeit und leichte Zugänglichkeit generativer Sprachmodelle die subjektive Wahrnehmung eigener Kompetenz fördert, ohne dass gleichzeitig ein entsprechend

tiefgehendes Wissen aufgebaut wird. Vielversprechend ist jedoch der beobachtete Anteil der Power User, der erkennen lässt, dass sich bereits ein wachsender Personenkreis mit fundiertem Wissen und reflektierter Anwendungskompetenz herausbildet. Diese Gruppe könnte künftig eine zentrale Rolle bei der Integration generativer KI in technisch anspruchsvolle ingenieurwissenschaftliche Aufgabenfelder übernehmen.

Im Rahmen der Untersuchung wurde ergänzend die Variable des Vertrauensscore analysiert, um die subjektive Sicherheit der Befragten im Umgang mit generativer KI zu erfassen. Der Vertrauensscore misst, in welchem Maße die Teilnehmenden generativen KI-Systemen Zuverlässigkeit, Transparenz und Nutzenpotenzial im beruflichen Kontext zuschreiben. Die deskriptive Auswertung zeigt, dass im Durchschnitt 60 % der Gesamtstichprobe ein ausgeprägtes Vertrauen in den Einsatz und den praktischen Nutzen generativer KI angeben. Dieses Ergebnis verdeutlicht eine grundsätzlich positive Grundhaltung gegenüber der Technologie und weist darauf hin, dass ein Großteil der Befragten die Leistungsfähigkeit generativer Modelle als relevant für ihre berufliche Tätigkeit einschätzt. Gleichzeitig lässt der verbleibende Anteil mit geringerer Vertrauensausprägung erkennen, dass trotz der breiten Akzeptanz weiterhin Unsicherheiten hinsichtlich Verlässlichkeit und Ergebnisqualität bestehen. Der Vertrauensscore liefert somit eine zentrale Kenngröße, um die Akzeptanzbedingungen und potenziellen Hemmnisse bei der Integration generativer KI im industriellen Umfeld analytisch zu bewerten.

Ausgehend von der Annahme, dass der zuvor dargestellte objektive Kenntnisstand eine zentrale kognitive Voraussetzung für einen erfolgreichen und sicheren Umgang mit generativer KI darstellt, wird an dieser Stelle der Zusammenhang zwischen dem Quizscore und dem Vertrauensscore empirisch überprüft. Die zugrunde liegende Hypothese wurde im Kapitel zur Hypothesenentwicklung hergeleitet und geht davon aus, dass ein höheres, auf Wissen basierendes Verständnis der Funktionsweise und Grenzen generativer KI-Systeme das Vertrauen in deren Ergebnisse stärkt. Zur Überprüfung dieses Zusammenhangs wurde eine Pearson-Korrelation durchgeführt. Dieses Verfahren ist angemessen, da beide Variablen metrisch skaliert sind und eine lineare Beziehung angenommen werden kann. Da sich die Hypothese spezifisch auf das Vertrauen in die Ergebnisse generativer KI-Modelle bezieht, wurde nicht der allgemeine Vertrauensscore, sondern das entsprechende Einzelitem der Erhebung verwendet, das explizit das Vertrauen in KI-generierte Ergebnisse erfasst.

Die Berechnung ergab einen Korrelationskoeffizienten von $r = -0{,}14$, was auf einen schwachen negativen, statistisch nicht signifikanten Zusammenhang zwischen objektivem Kenntnisstand und Vertrauen in die Ergebnisse generativer KI-Modelle hinweist. Damit findet sich kein

empirischer Beleg dafür, dass ein höherer Wissensstand mit einem stärkeren Vertrauen in die Resultate generativer KI-Systeme einhergeht. Das ergänzend berechnete Bestimmtheitsmaß von $R^2 = 0{,}02$ zeigt, dass der objektive Kenntnisstand lediglich 2% der Varianz im Vertrauen erklärt und somit keine relevante erklärende Wirkung aufweist. Dieses Ergebnis legt nahe, dass Vertrauen in generative KI nicht primär kognitiv fundiert ist, sondern stärker durch andere Einflussfaktoren geprägt wird, beispielsweise durch persönliche Nutzungserfahrungen oder technologische Offenheit. An dieser Stelle wird folglich die Nullhypothese, die keinen signifikanten Zusammenhang zwischen den Variablen annimmt, bestätigt. (Bortz & Schuster, 20; Backhaus et. al., 2021)

Im Rahmen der Hypothesenentwicklung wurde darüber hinaus ein Wirkungszusammenhang zwischen Wissen, Vertrauen und Nutzung generativer KI im industriellen Kontext formuliert. Ausgangspunkt war die Annahme, dass der objektive Kenntnisstand, verstanden als tatsächliches Wissen über Funktionsweise und Grenzen der Technologie, die Entwicklung von Vertrauen in generative KI fördert. Dieses Vertrauen wiederum sollte die wahrgenommene subjektive Kompetenz stärken und dadurch den häufigeren Einsatz generativer KI im Arbeitsprozess begünstigen. Vertrauen wurde dabei als vermittelnde Variable zwischen Wissen und Nutzung konzipiert, die den Übergang von kognitiver Kompetenz zu praktischer Anwendung unterstützt. Die empirischen Befunde zeichnen jedoch ein differenziertes Bild. Der durchschnittliche objektive Kenntnisstand fällt mit 37 % korrekt beantworteten Quizfragen vergleichsweise niedrig aus, während der subjektive Kenntnisstand mit 47 % höher liegt und eine leichte Überschätzung der eigenen Fähigkeiten erkennen lässt. Das Vertrauen in generative KI wird von 60% der Befragten als hoch eingeschätzt und die Nutzungshäufigkeit liegt im Mittel bei einer Anwendung alle zwei bis drei Tage. Auch der Zusammenhang zwischen objektivem Wissen und dem allgemeinen Vertrauensscore zeigt mit $r = 0{,}09$ keine statistische Signifikanz. Diese Befunde deuten darauf hin, dass der angenommene kognitive Wirkungszusammenhang empirisch nicht bestätigt werden kann. Vertrauen in generative KI scheint demnach nicht primär wissensbasiert, sondern stärker erfahrungs- oder nutzungsorientiert geprägt zu sein. Während Wissen eine notwendige Grundlage für den reflektierten Umgang mit der Technologie bildet, entsteht Vertrauen offenbar unabhängig davon. Damit legt die Analyse nahe, dass Vertrauen im Wirkgefüge zwischen Wissen und Nutzung eine eigenständige, weniger kognitiv als praktisch geprägte Rolle einnimmt und der theoretisch angenommene lineare Wirkungszusammenhang in der untersuchten Stichprobe nur teilweise zutrifft.

Im Zusammenhang mit dem vergleichsweisen gering ausgeprägten Vertrauen in generative KI zeigt zudem die Analyse der Variable Risikowahrnehmung, dass rund 60 % der Befragten potenzielle Risiken beim Einsatz dieser Technologie erkennen. Dieses Ergebnis verdeutlicht, dass ein erheblicher Teil der Teilnehmenden dem Einsatz generativer KI mit einer gewissen Vorsicht begegnet. Die ausgeprägte Risikowahrnehmung spiegelt somit eine kritisch reflektierte Haltung wider, die auf ein Bewusstsein für Unsicherheiten, potenzielle Fehlfunktionen sowie ethische und sicherheitsrelevante Herausforderungen im industriellen Anwendungskontext hinweist.
Schließlich bewerteten 68 % der Teilnehmenden das Einsatzpotenzial generativer KI als hoch. Dieses Ergebnis deutet darauf hin, dass die befragten Fachkräfte der Technologie grundsätzlich eine wachsende Bedeutung für ihre berufliche Praxis beimessen, auch wenn der aktuelle Einsatz vorwiegend unterstützende und sprachlich orientierte Aufgaben betrifft. Die Ergebnisse machen deutlich, dass generative KI im Maschinenbau bereits regelmäßig genutzt wird, ihr Einsatz jedoch noch selektiv erfolgt und von individuellen Arbeitskontexten abhängt.
Im Gesamtbild der Auswertung zeigt sich, dass generative KI inzwischen einen festen, wenn auch begrenzten Platz im Arbeitsalltag einnimmt. Eine umfassende Integration in technische Kernprozesse steht dagegen noch aus. Der gegenwärtige Entwicklungsstand lässt sich als Übergangsphase beschreiben, in der generative Anwendungen vor allem zur Effizienzsteigerung, zur Aufbereitung von Wissen und zur Unterstützung analytischer Tätigkeiten beitragen. Die Einschätzungen der Befragten deuten zugleich auf eine vorsichtig positive Erwartung hin, dass die Bedeutung generativer Systeme künftig zunehmen und sich ihr Einsatz schrittweise auf komplexere ingenieurtechnische Aufgabenfelder ausweiten wird.

### *7.2.1 Aktueller Stand und empirisch beobachtete Nutzung generativer KI im Maschinenbau*

Die empirischen Ergebnisse verdeutlichen, dass sich der gegenwärtige Einsatz generativer KI im Maschinenbau in einer fortgeschrittenen, jedoch noch nicht vollständig institutionalisierten Phase befindet. Mit einer Nutzungsquote von 95 % unter den Befragten zeigt sich, dass generative KI-Anwendungen bereits weit über die experimentelle Erprobung hinaus in den beruflichen Alltag integriert sind. Nur 5% der Teilnehmenden gaben an, bislang keine generative KI zu verwenden. Diese Verteilung deutet auf eine hohe Marktdurchdringung und auf die Etablierung der Technologie als anerkanntes Arbeitswerkzeug im ingenieurtechnischen Umfeld hin. Generative KI hat sich damit von einer neuartigen, explorativen Anwendung zu einem festen Bestandteil professioneller Tätigkeiten entwickelt, auch wenn die Integration noch nicht auf organisationaler oder systemischer Ebene verankert ist. Die Nutzungshäufigkeit liefert ergän-

zende Hinweise auf den Entwicklungsstand der Integration. Innerhalb eines Betrachtungszeitraums von 30 Tagen wurde generative KI durchschnittlich alle zwei bis drei Tage im Arbeitskontext verwendet. Diese Häufigkeit zeigt, dass generative KI regelmäßig und gezielt eingesetzt wird, zugleich aber weiterhin in hohem Maße anwendergetrieben bleibt. Der Einsatz erfolgt überwiegend aus der Eigeninitiative einzelner Fachkräfte, die die Technologie nutzen, um Routineaufgaben zu vereinfachen oder bestimmte Arbeitsschritte zu beschleunigen. Eine formalisierte, organisationsweite Implementierung lässt sich aus den Ergebnissen hingegen noch nicht ableiten. Dieses Muster kennzeichnet den Übergang von der individuellen Nutzung zur strukturierten, prozessübergreifenden Anwendung, also eine Zwischenphase zwischen Einführung und institutionalisierter Integration. Im Vergleich mit industrieweiten Studien bestätigt sich diese Einschätzung. 27 % der Unternehmen untersuchen derzeit das Potenzial generativer KI, 52 % führen Pilotprojekte durch, während nur 6% die Technologie bereits in mehreren Funktionen oder Unternehmensbereichen systematisch implementiert haben (Capgemini, 2015). Auch externe Erhebungen zeigen, dass 53 Prozent der deutschen Erwerbstätigen erste Erfahrungen mit generativer KI gesammelt haben (Forsa-Institut, 2025). Diese Ergebnisse deuten darauf hin, dass die Technologie inzwischen eine breite Basis an Nutzenden erreicht hat, der Reifegrad der Implementierung aber noch in der Entwicklungsphase liegt. Die empirischen Befunde dieser Untersuchung verdeutlichen, dass generative KI im Maschinenbau vor allem in sprachlich- und wissensbasierten Tätigkeitsfeldern eingesetzt wird. Zu den am häufigsten genannten Einsatzfeldern zählen die strukturierte Informationsrecherche, die Zusammenfassung technischer oder wissenschaftlicher Texte, die sprachliche Aufbereitung komplexer Sachverhalte, Übersetzungsaufgaben sowie die inhaltliche Optimierung technischer Dokumente. In diesen Bereichen fungiert generative KI als kognitives Assistenzsystem, das die Informationsverarbeitung erleichtert, Inhalte aufbereitet und Routineprozesse automatisiert. Rund 70 % der Befragten bestätigten, dass der Einsatz generativer KI ihre tägliche Arbeit spürbar effizienter gestaltet.

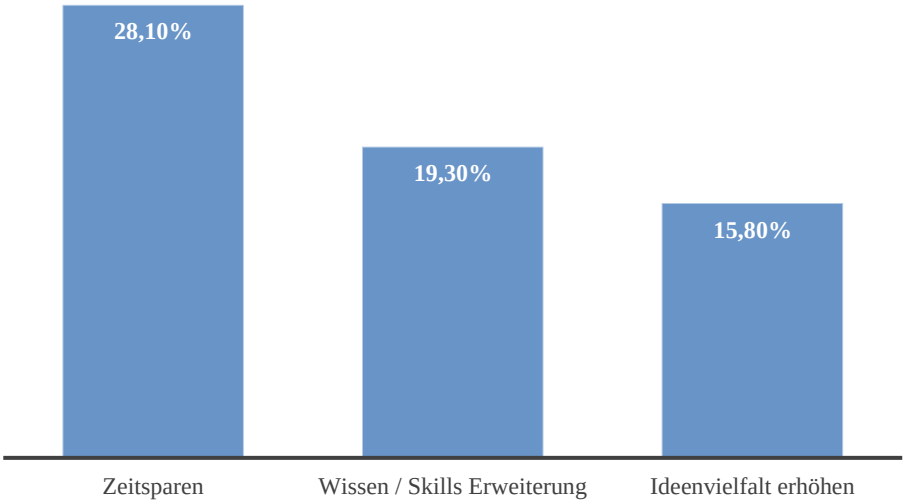


*Abbildung 17: Prioritäten der Stichprobe im Nutzungskontext generativer KI. Eigene Darstellung.*

Die Prioritäten im Nutzungskontext spiegeln diesen Fokus auf Effizienz und Wissensverarbeitung wider. Als wichtigster Zielfaktor wurde mit 28 % die Zeiteinsparung genannt, gefolgt von der Erweiterung von Wissen und fachlicher Kompetenz mit 19 % sowie kreativen Impulsen mit 15 %. Diese Ergebnisse zeigen, dass generative KI im Maschinenbau vor allem als Mittel zur Steigerung von Produktivität, Wissensintensität und Innovationsfähigkeit wahrgenommen wird. Dabei steht weniger die vollständige Automatisierung technischer Prozesse im Vordergrund, sondern die gezielte Unterstützung kognitiver und sprachlicher Tätigkeiten, etwa bei der Informationsgewinnung, Dokumentation oder Ideenentwicklung.

Auffällig ist, dass die am häufigsten genutzte Anwendung Chat GPT ist. Diese Dominanz erklärt sich durch die frühe öffentliche Verfügbarkeit, die hohe Benutzerfreundlichkeit und die starke mediale Präsenz des Systems. Nach der Veröffentlichung im Jahr 2022 wurde Chat GPT schnell zum bekanntesten generativen KI-Modell weltweit und auch im deutschsprachigen Raum in den Berufsalltag integriert. Durchschnittlich erschienen in den ersten Monaten nach Veröffentlichung zwischen 200 und 400 Artikel pro Woche, was eine breite Wissensdiffusion und gesellschaftliche Sichtbarkeit der Technologie bewirkte (Büchel & Engler, 2024). Durch diese mediale Dynamik entstand eine frühe Akzeptanzschwelle, die den Zugang zur Technologie erheblich erleichterte und deren Erprobung in verschiedensten Berufsfeldern förderte. Die empirischen Ergebnisse dieser Untersuchung stützen die Annahme, dass generative KI derzeit vor allem dort Anwendung findet, wo sprachliche Inhalte verarbeitet oder optimiert werden. In diesen Aufgabenfeldern übernimmt die Technologie keine substitutive, sondern eine komplementäre Funktion, die die kognitive Arbeit von Ingenieur: innen unterstützt. Sie ermöglicht eine

schnellere Informationsbeschaffung, eine präzisere Textaufbereitung und eine effizientere Dokumentation. Die dadurch gewonnene Zeit- und Arbeitsersparnis eröffnet wiederum Spielräume für komplexere, wertschöpfende Tätigkeiten. Gleichzeitig zeigen die Daten eine deutliche Begrenzung in der technologischen Tiefe des Einsatzes. Der nachgewiesene Nutzen konzentriert sich vorwiegend auf einfache, Large-Language-Model-basierte Systeme, die auf textuelle Aufgaben spezialisiert sind. Eine Integration in komplexe ingenieurtechnische Tätigkeiten, etwa in CAD-gestützte Konstruktion, Simulation, Prozessplanung oder automatisierte Fertigungssteuerung, bleibt bislang weitgehend aus. Diese Diskrepanz verdeutlicht den aktuellen Reifegrad generativer KI im Maschinenbau. Während die Technologie im Bereich der Wissensorganisation und Informationsverarbeitung bereits produktiv eingesetzt wird, befindet sich ihre systematische Einbettung in technische Kernprozesse noch im Anfangsstadium.

Insgesamt lässt sich der aktuelle Stand des Einsatzes generativer KI im Maschinenbau als Phase der breiten, aber selektiven Nutzung charakterisieren. Die Technologie ist funktional etabliert und unterstützt ingenieurtechnische Arbeitsprozesse spürbar, doch ihre Integration bleibt überwiegend auf individuelle Initiativen und sprachbasierte Anwendungsfelder beschränkt. Damit markiert der beobachtete Zustand einen Übergang von der explorativen Erprobung zur strukturierten Implementierung, in dem generative KI zwar als Effizienztreiber und Wissensverstärker wirkt, ihr Potenzial zur tiefgreifenden Einbindung in technische Kernprozesse jedoch erst in den kommenden Entwicklungsschritten entfalten wird.

## 8 Ausblick

Die empirischen Ergebnisse zeigen ein ambivalentes Bild im Verhältnis zwischen Wissen, Vertrauen und Nutzung generativer KI. Während der objektive Kenntnisstand der Befragten mit durchschnittlich 37 % richtig beantworteter Quizfragen auf ein begrenztes technisches Verständnis hinweist und das Vertrauen in die Ergebnisse generativer Modelle mit 35 % insgesamt gering ausfällt, nutzen dennoch viele Teilnehmende entsprechende Anwendungen regelmäßig, im Durchschnitt alle zwei bis drei Tage. Parallel dazu zeigt die Variable der Risikowahrnehmung, dass rund 60 % der Befragten potenzielle Risiken und Unsicherheiten im Zusammenhang mit generativer KI erkennen. Dieses Befundmuster verweist auf eine klare Diskrepanz zwischen kognitiver Einschätzung und praktischem Handeln, trotz begrenzten Wissens, moderaten Vertrauens und hoher Risikosensibilität wird generative KI aktiv und häufig eingesetzt.

Dieses scheinbar widersprüchliche Verhalten lässt sich aus theoretischer und psychologischer Perspektive durch mehrere Wirkmechanismen erklären. Zunächst ist nach dem TAM-Modell

die wahrgenommene Nützlichkeit eine der zentralen Determinanten technologischer Nutzung. Anwendungen wie Chat GPT liefern unmittelbare, greifbare Vorteile im Arbeitsalltag, etwa Zeitersparnis, kreative Unterstützung oder vereinfachte Text- und Ideengenerierung. Diese konkreten Effizienzgewinne führen dazu, dass der wahrgenommene Nutzen die bestehenden Vorbehalte überwiegt. Selbst wenn Unsicherheiten hinsichtlich Genauigkeit, Nachvollziehbarkeit oder Datenschutz bestehen, ist die subjektive Bewertung der praktischen Vorteile oft ausschlaggebender als kognitive Bedenken. Der Nutzen wird damit zur dominanten Triebkraft der Nutzung, während Vertrauen eine nachgelagerte oder sekundäre Rolle einnimmt. Darüber hinaus fördern Zugänglichkeit und Bedienungsfreundlichkeit generativer Sprachmodelle die Nutzung auch bei Personen mit geringerem Wissen oder anfänglicher Skepsis. Chat GPT ist frei verfügbar, unmittelbar nutzbar und erfordert keine technischen Vorkenntnisse. Diese niedrigen Eintrittsbarrieren senken das wahrgenommene Risiko des Experimentierens. Viele Nutzer: innen gelangen daher nicht über kognitive Überzeugung, sondern über praktische Erfahrung zur Nutzung. Vertrauen ist in diesem Fall nicht Voraussetzung, sondern Ergebnis wiederholter positiver Interaktionen mit dem System. Ein weiterer Faktor ist die soziale Normalisierung der Nutzung. Generative KI hat sich in kurzer Zeit zu einem gesellschaftlich sichtbaren Phänomen entwickelt. In beruflichen Netzwerken, Medien und Bildungskontexten ist der Einsatz von Chat GPT weit verbreitet. Diese soziale Akzeptanz schafft normative Erwartungen. Wer generative KI nutzt, gilt als innovativ und anschlussfähig. Das erzeugt einen gewissen sozialen Druck zur Nutzung, unabhängig von individuellem Vertrauen oder Wissen. Vertrauen wird somit teilweise ersetzt durch soziale Legitimation und Nutzung wird zur Routine, nicht zur Überzeugungstat. Schließlich ist zu berücksichtigen, dass das beobachtete Vertrauen in vielen Fällen kein umfassendes, sondern ein funktionales Vertrauen darstellt. Nutzer: innen vertrauen Chat GPT nicht blind, sondern kontextbezogen, etwa für Recherche, Ideenfindung oder sprachliche Unterstützung, nicht jedoch für sicherheitskritische Entscheidungen. Dieses selektive Vertrauen erlaubt eine pragmatische Balance zwischen Nutzen und Risiko. Die Technologie wird genutzt, aber ihre Ergebnisse werden kritisch geprüft.

Für die zukünftige Entwicklung ergibt sich daraus die Notwendigkeit, Maßnahmen zur gezielten Kompetenzförderung und Wissensvermittlung zu etablieren. Schulungen und praxisnahe Weiterbildungsformate können einen entscheidenden Beitrag dazu leisten, das Vertrauen in generative Systeme zu stärken und bestehende Vorbehalte abzubauen. Durch die aktive Auseinandersetzung mit den Funktionsprinzipien und Anwendungsmöglichkeiten der Technologie

können Fachkräfte ein realistisches Verständnis ihrer Leistungsfähigkeit entwickeln und gleichzeitig lernen, Risiken angemessen einzuschätzen. Ein solcher Lernprozess fördert nicht nur den sicheren und reflektierten Umgang mit generativer KI, sondern unterstützt auch den bewussten Einsatz in unterschiedlichen technischen Kontexten. Darüber hinaus kann die frühzeitige Integration generativer KI in Arbeits- und Lernprozesse dazu beitragen, die bestehende Distanz zwischen technologischem Potenzial und praktischer Nutzung zu verringern. Die Konfrontation mit realen Anwendungsfällen und der Austausch über Chancen und Grenzen der Technologie stärken die Fähigkeit, generative KI kritisch, aber konstruktiv in den Arbeitsalltag einzubinden. Langfristig kann dadurch eine fundierte Vertrauenskultur entstehen, die auf Wissen, Erfahrung und transparenter Kommunikation basiert. Im Ausblick zeigt sich somit, dass der nachhaltige Erfolg generativer KI im industriellen Umfeld nicht allein von technologischen Fortschritten abhängt, sondern maßgeblich davon, wie gut Fachkräfte befähigt werden, diese Systeme kompetent und verantwortungsvoll zu nutzen. Eine gezielte Verbindung aus technischer Schulung, praxisnaher Anwendung und offener Auseinandersetzung mit Risiken bildet die Grundlage für eine stabile und zukunftsorientierte Integration generativer KI im Maschinenbau.

Wie auch aus den theoretischen Befunden der Literatur hervorgeht, stützen die vorliegenden Ergebnisse die derzeitige wissenschaftliche Diskussion über die wachsende Bedeutung generativer KI im industriellen Umfeld. In vielen Studien wird beschrieben, dass generative KI nicht nur, wie auch die empirischen Befunde dieser Arbeit zeigen, zur Steigerung von Effizienz und Produktivität in technischen Prozessen beiträgt, sondern zunehmend als Instrument zur Unterstützung komplexer Entwicklungs- und Entscheidungsprozesse im Ingenieurwesen betrachtet werden kann. Dennoch ist dieser Befund vor dem Hintergrund des frühen Entwicklungsstandes der Technologie und des fortlaufenden strukturellen Wandels von Arbeitsprozessen mit Zurückhaltung zu bewerten. Es ist anzunehmen, dass die Implementierung generativer KI in ingenieurtechnischen Tätigkeitsfeldern in den kommenden Jahren allmählich zunehmen wird. Die bisherige Nutzung einfacher, frei zugänglicher Systeme, vor allem für klar umrissene und unterstützende Aufgaben, zeigt, dass sich generative KI in einer frühen, aber stabilen Phase der praktischen Etablierung befindet. Die Beobachtungen deuten darauf hin, dass der technologische Fortschritt in diesem Bereich gegenwärtig nicht auf Widerstand stößt, sondern mit Vorsicht beobachtet und schrittweise erprobt wird. Insgesamt lässt sich daraus schließen, dass generative KI bereits eine funktionale, wenn auch begrenzte Rolle im ingenieurtechnischen Arbeitskontext einnimmt und ihre weitere Integration in hohem Maß von der technologischen

Reife, der Zuverlässigkeit der Systeme und der Anpassungsbereitschaft der Organisationen abhängen wird. Für Forschung und Praxis eröffnet sich daraus ein breites Feld zukünftiger Fragestellungen. Im Vordergrund steht die Notwendigkeit, die Wechselwirkungen zwischen technologischem Potenzial, menschlicher Kompetenz und organisatorischer Anpassung besser zu verstehen. Dabei wird entscheidend sein, wie Ingenieurinnen und Ingenieure befähigt werden können, generative KI nicht nur als Hilfsmittel, sondern als integralen Bestandteil technischer Wertschöpfung zu nutzen. Zukünftige Untersuchungen sollten daher verstärkt darauf ausgerichtet sein, die Wirkungen generativer KI auf Arbeitsprozesse, Entscheidungslogik und Innovationsdynamik empirisch zu erfassen und aus einer interdisziplinären Perspektive zu bewerten.

Abschließend lässt sich festhalten, dass generative KI im Maschinenbau bereits heute ein erkennbares Potenzial zur Effizienzsteigerung und Wissensunterstützung besitzt, ihre tiefgreifende Wirkung auf technische Entwicklungs- und Konstruktionsprozesse jedoch erst in den kommenden Jahren entfalten wird. Die gegenwärtige Phase kann als Ausgangspunkt für eine langfristige Transformation verstanden werden, in der sich der industrielle Umgang mit Wissen, Kreativität und Automatisierung neu ausrichtet. Die hier gewonnenen Erkenntnisse liefern damit einen ersten empirischen Beitrag zur Einordnung dieses Wandlungsprozesses und schaffen eine Grundlage für weiterführende Forschung, die den Übergang von der punktuellen Anwendung zur strategischen Integration generativer KI im Maschinenbau begleiten wird.

**Literaturverzeichnis**

**(Abdelaal et. al., 2025)**

Abdelaal, M., Lokadjaja, S., & Engert, G. (2025). GLLM: Self-Corrective G-Code Generation using Large Language Models with User Feedback [Preprint]. arXiv. https://arxiv.org/abs/2501.17584

**(Al-Amin et. al., 2024)**

Al-Amin, M., Ali, M. S., Salam, A., Ali, A., Ullah, A., Alam, M. N., & Chwodhury, S. K. (2024). History of generative artificial intelligence (AI) chatbots: Past, present, and future development (arXiv Preprint No. 2402.05122). https://doi.org/10.48550/arXiv.2402.05122

**(Anam, 2025)**

Anam, R. K. (2025). Prompt engineering and the effectiveness of large language models in enhancing human productivity [Preprint]. arXiv. https://arxiv.org/abs/2507.18638

**(Azab et. Al., 2024)**

Azab, A., Osman, H., & Baki, F. (2024). CAPP-GPT: A computer-aided process planning-generative pretrained transformer framework for smart manufacturing. Manufacturing Letters, 41, 51–62. https://doi.org/10.1016/j.mfglet.2024.02.004

**(Backhaus et. al., 2006)**

Backhaus, K., Erichson, B., Plinke, W., & Weiber, R. (2006). Multivariate Analysemethoden: Eine anwendungsorientierte Einführung (10., überarb. Aufl.). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-14987-0 Unter Research Gate: (PDF) Multivariate Analysemethoden

**(Banh et. al., 2025)**

Banh, L., Holldack, F., & Strobel, G. (2025). Copilot in die Zukunft: Wie generative KI das Software Engineering transformiert. Information and Software Technology, 183, 107751. https://doi.org/10.1016/j.infsof.2025.107751

**(Bandow & Holzmüller, 2009)**

Bandow, G., & Holzmüller, H. H. (2009). Das Experteninterview als Methode der Organisationsforschung. In H. H. Holzmüller & G. Bandow (Hrsg.), Wirtschaftspsychologie – Grundlagen und Anwendungen unternehmerischen Denkens und Handelns (S. 227–251). Springer Gabler. https://doi.org/10.1007/978-3-531-91452-7_12

**(Bendel & Latniak, 2023)**

**Bendel, A., & Latniak, E. (2023).** Weiter so mit MTO? Konzeptionelle Entwicklungsbedarfe soziotechnischer Arbeits- und Systemgestaltung. Gruppe. Interaktion. Organisation. Zeit-schrift für Angewandte Organisationspsychologie (GIO), 54, 9–26. https://doi.org/10.1007/s11612-023-00669-6

**(Berger et. al., 2024)**

Berger, E., Braun, F., Mehlstäubl, J., & Paetzold-Byhain, K. (2024). Applications of gen-erative AI in the product development process: A scoping review. In Proceedings of the 35th DfX Symposium 2024. https://doi.org/10.35199/dfx2024.06

**(Berger et. al., 2025)**

Berger, E., Dammann, M. P., Mehlstäubl, J., Saske, B., & Paetzold-Byhain, K. (2025, Juni). Anwendungsfälle und Implementierungsbarrieren für generative KI in CAD-Prozessen [Use-cases and implementation barriers for generative AI-supported CAD processes]. In Stuttgarter Symposium für Produktionentwicklung. Technische Universität Dresden. Verfügbar unter https://www.researchgate.net/publication/392655220_Anwendungsfalle_und_Implementierungsbarrieren_fur_generative_KI_in_CAD-_Prozessen_Use-Cases_and_Implementation_barriers_for_generative_AI-supported_CAD_processes

**(Benner, 1984)**

Benner, P. (1984). From novice to expert: Excellence and power in clinical nursing practice. Menlo Park, CA: Addison-Wesley.
DOI: 10.1097/00000446-198412000-0002

Verfügbar unter: https://www.researchgate.net/publication/232117087_From_Novice_To_Expert_Excellence_and_Power_in_Clinical_Nursing_Practice

**(Bundesagentur für Arbeit, 2025)**

Bundesagentur für Arbeit. (15. Januar, 2025). Anteil von Frauen und Männern in verschie-denen Berufsgruppen in Deutschland am 30. Juni 2024 (sozialversicherungspflichtig und ge-ringfügig Beschäftigte) [Graph]. In Statista. Zugriff am 29. Oktober 2025, von https://de.statista.com/statistik/daten/studie/167555/umfrage/frauenanteil-in-verschiedenen-berufsgruppen-in-deutschland/

**(Bortz & Schuster, 2010)**

Bortz, J., & Schuster, C. (2010). Statistik für Human- und Sozialwissenschaftler (7., überarb. Aufl.). Springer. https://link.springer.com/book/10.1007/978-3-642-12770-0

**(Büchel & Engler, 2024)**

Büchel, J., & Engler, J. (2024). Generative KI in Deutschland: Künstliche Intelligenz in Gesellschaft und Unternehmen (IW-Report Nr. 23/2024). Institut der deutschen Wirtschaft (IW). https://hdl.handle.net/10419/294841

**(Bühner, 2011)**

Bühner, M. (2011). Einführung in die Test- und Fragebogenkonstruktion (2., aktualisierte und erweiterte Aufl.). Pearson Studium. https://www.researchgate.net/publication/28358158_Einfuhrung_in_die_Test-_und_Fragebogenkonstruktion

**(Byrne et. al., 2024)**

Byrne, D., Hargaden, V., & Papakostas, N. (2024). Application of generative AI technologies to engineering design. In Proceedings of the 12th CIRP Global Web Conference (CIRPe 2024). Procedia CIRP. https://doi.org/10.1016/j.procir.2025.01.025

**(Capgemini, 2025)**

Capgemini. (8. September, 2025). Umfrage zur Nutzung generativer KI in Unternehmen, nach Funktion in den Jahren 2023 bis 2025 [Graph]. In Statista. Zugriff am 31. Oktober 2025, von https://de.statista.com/statistik/daten/studie/1483724/umfrage/kuenstliche-intelligenz-nutzung-generativer-ki-in-unternehmen-nach-funktion/

**(Cantamessa & Montagna, 2023)**

Cantamessa, M., & Montagna, F. (2023). Management of innovation and product develop-ment: Integrating business and technological perspectives (2nd ed.). Springer. https://doi.org/10.1007/978-1-4471-7531-5

**(Carretero et. al., 2017)**

Carretero, S., Vuorikari, R., & Punie, Y. (2017). DigComp 2.1: The digital competence framework for citizens with eight proficiency levels and examples of use. Publications Office of the European Union. https://doi.org/10.2760/38842

**(Daaryeni et. Al., 2025)**

Daareyni, A., Martikkala, A., Mokhtarian, H., & Flores Ituarte, I. (2025). Generative AI meets CAD: Enhancing engineering design to manufacturing processes with large language models. The International Journal of Advanced Manufacturing Technology. https://doi.org/10.1007/s00170-025-15830-2

**(Diekmann, 2020)**

Diekmann, A. (2020). Empirische Sozialforschung: Grundlagen, Methoden, Anwendungen (13., vollständig überarb. und erw. Aufl.). Rowohlt Verlag. https://www.researchgate.net/publication/361651626_Diekmann_Andreas_2020_Empirische_Sozialforschung_Grundlagen_Methoden_Anwendungen_13_Aufl_der_Neuausgabe_Reinbek_Rowohlt

**(Dreyfus & Dreyfus, 1980)**

Dreyfus, S. E., & Dreyfus, H. L. (1980). A five-stage model of the mental activities involved in directed skill acquisition. University of California, Berkeley, Operations Research Center.

Verfügbar unter: https://www.researchgate.net/publication/235125013_A_Five-Stage_Model_of_the_Mental_Activities_Involved_in_Directed_Skill_Acquisition

**(Egger, 2022)**

Egger, J. W. (2022). Selbstwirksamkeit und Selbstwirksamkeitserwartung – ein wirkmächtiges kognitives Konstrukt für gesundheitliches Verhalten. Psychologie in Österreich, 5(2020), 327–334. https://www.researchgate.net/publication/359025528_Selbstwirksamkeit_und_Selbstwirksamkeitserwartung_-_ein_wirkmachtiges_kognitives_Konstrukt_fur_gesundheitliches_Verhalten

**(Ertel, 2016)**

Ertel, W. (2016). Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung. (4.Aufl.). Springer Vieweg. https://doi.org/10.1007/978-3-658-13549-2

**(Filz et. al., 2024)**

Filz, M.-A., & Thiede, S. (2024). Generative AI in manufacturing systems: Reference framework and use cases. In Proceedings of the 57th CIRP Conference on Manufacturing Systems (CMS 2024). Elsevier B.V. https://doi.org/10.1016/j.procir.2024.10.082

**(Fukuda, 2019)**

Fukuda, K. (2019). Society 5.0: Aiming for a new human-centered society. Japan Spotlight, 28(2), 47–50. https://link.springer.com/book/10.1007/978-3-030-26725-4

**(Gerhard et. al., 2025)**

Gerhard, D., Neges, H.-M., Köring, T., & Uzair, M. (2025). Optimierung von Entwick-lungsprozessen durch KI-gestütztes generative Engineering und Design. ZWF – Zeitschrift für wirtschaftlichen Fabrikbetrieb, 120(S1), 70-75. https://doi.org/10.1515/zwf-2024-0140

**(Goodfellow et. Al., 2014)**

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Cour-ville, A., & Bengio, Y. (2014). Generative adversarial networks. arXiv. https://doi.org/10.48550/arXiv.1406.2661

**(Gupta et. al., 2025)**

Gupta, R., Tiwari, S., & Chaudhary, P. (2025). Generative AI: Techniques, models and applications. Springer. https://doi.org/10.1007/978-3-031-82062-5

**(Heigl, 2025)**

Heigl, R. (2025). Generative artificial intelligence in creative contexts: A systematic review and future research agenda. Management Review Quarterly. Advance online publication. https://doi.org/10.1007/s11301-025-00494-9

**(Holtzman et.al., 2019)**

Holtzman, A., Buys, J., Du, L., Forbes, M., & Choi, Y. (2019). The Curious Case of Neural Text Degeneration (arXiv preprint arXiv:1904.09751). arXiv. https://doi.org/10.48550/arXiv.1904.09751

**(ten Hompel, 2023)**

Hompel, M. ten, Lappe, D., & Overmeyer, L. (2023). Logistik im Wandel – Perspektiven und Herausforderungen bis 2030. Dortmund: Fraunhofer IML.

**(Huang & Peissl, 2023)**

Huang, L., & Peissl, W. (2023). Künstliche Intelligenz – ein neues Paradigma für Wissen und Entscheidungsfindung) In L. Hennen, J. Hahn, M. Ladikas, R. Lindner, W. Peissl & R. van Est (hrsg), Technikfolgenabschätzung in einer globalisierten Welt (S.147-162). Springer, Cham. https://doi.org/10.1007/978-3-031-10617-0_9

**(Jacovi et. al., 2020)**

Jacovi, A., Marasović, A., Miller, T., & Goldberg, Y. (2020). Formalizing trust in artificial intelligence: Prerequisites, causes and goals of human trust in AI [Preprint]. arXiv. https://doi.org/10.48550/arXiv.2010.07487

**(Ji et. Al., 2022)**

Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y., Chen, D., Dai, W., Chan, H. S., Madotto, A., & Fung, P. (2022). Survey of Hallucination in Natural Language Generation (arXiv preprint arXiv:2202.03629). arXiv. https://doi.org/10.48550/arXiv.2202.03629

**(IT-P GmbH, 2024)**

IT-P GmbH. (2024, 26. Februar). Die Geschichte der KI: Ein Rückblick von den Ursprün-gen bis zur Moderne. KI Home. https://www.it-p.de/blog/geschichte-ki

**(Jiang et. al., 2025)**

Jiang, S., Li, W., Qian, Y., Zhang, Y., & Luo, J. (2025, März 24). Auto-TRIZ: Automating engineering innovation with TRIZ and large language models. In Proceedings of the ASME 2024 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference (IDETC/CIE 2024). https://doi.org/10.1115/DETC2024-143166 Verfügbar unter: https://doi.org/10.48550/arXiv.2403.13002

**(Kakas, 2025)**

Kakas, A., C. (2025). Aristoteles ursprüngliche Idee: für und gegen Logik im Zeitalter der KI. arXiv. https://doi.org/10.48550/arXiv.2503.12161

**(Kausik et. al., 2025)**

Kausik, A. K., Rashid, A. B., Baki, R. F., & Maktum, M. M. J. (2025). Algorithmen des maschinellen Lernens für die Qualitätssicherung in der Fertigung: Eine systematische Überprüfung von Leistungskennzahlen und Anwendungen. Array, 20, 100393. https://doi.org/10.1016/j.array.2025.100393

**(Kinder et. Al., 2024)**

Kinder, M., de Souza Briggs, X., Muro, M., & Liu, S. (2024, October 19). Generative AI, the American worker, and the future of work. Brookings Institution.

Abgerufen am (12.09.2025) https://www.brookings.edu/articles/generative-ai-the-american-worker-and-the-future-of-work/

**(Kretzschmar et. al., 2024)**

Kretzschmar, M., Dammann, M. P., Schwoch, S., & Paetzold, K. (2024). Evaluating the role of generative AI in product development and design: A systematic review. In Proceedings of NordDesign 2024 (pp. 1–12). Reykjavík, Iceland. https://doi.org/10.35199/NORDDESIGN2024.3 Verfügbar

unter: https://www.researchgate.net/publication/383819894_Evaluating_the_Role_of_Generative_AI_in_Product_Development_and_Design_-_A_Systematic_Review

**(Kwon et. al., 2024)**

Kwon, J., Jung, E.-C., & Kim, J. (2024). Designer–generative AI ideation process: Generating images aligned with designer intent in early-stage concept exploration in product design. Archives of Design Research, 37(3), 7–23. https://doi.org/10.15187/adr.2024.07.37.3.7 Verfügbar unter https://www.researchgate.net/publication/382942226_Designer-Generative_AI_Ideation_Process_Generating_Images_Aligned_with_Designer_Intent_in_Early-Stage_Concept_Exploration_in_Product_Design

**(Lewis et. al., 2020)**

Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Wen-tau Yih, Rocktäschel, T., Riedel, S., & Kiela, D. (2020). Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks (arXiv:2005.11401). arXiv. https://doi.org/10.48550/arXiv.2005.11401

**(Li et. al., 2025)**

Li, K.-Y., Huang, C.-K., Chen, Q.-W., Zhang, H.-C., & Tang, T.-T. (2025). Generative AI and CAD automation for diverse and novel mechanical component designs under data con-straints. Discover Applied Sciences. https://doi.org/10.1007/s42452-025-06833-5

**(Lin et. al., 2024)**

Lin, H., Jiang, X., Deng, X., Bian, Z., Fang, C., & Zhu, Y. (2024). Comparing AIGC and traditional idea generation methods: Evaluating their impact on creativity in the product design ideation phase. Thinking Skills and Creativity, 53, 101649. https://doi.org/10.1016/j.tsc.2024.101649

**(Mainzer, 2019)**

Mainzer, K. (2019). Künstliche Intelligenz – Wann übernehmen die Maschinen? (2.Aufl.). Springer. https://doi.org/10.1007/978-3-662-58046-2

**(Mohapatra, 2024)**

Mohapatra, A. (2024). Generative AI for predictive maintenance: Predicting equipment failures and optimizing maintenance schedules using AI. International Journal of Scientific Research and Management (IJSRM), 12(11), 1648–1672. https://doi.org/10.18535/ijsrm/v12i11.ec03

**(Morlock, 2024)**

Morlock, F. (2024). Fabrikbetriebsorganisation (FBO): Produktentstehungsprozess (PEP), Auftragsabwicklung, Arbeitsvorbereitung [Vorlesungsfolien]. Hochschule Ruhr West.

**(Morlock et. al., 2025)**

Morlock, F., Grzywaczyk, J., Hamidi, A. (2025). Einsatzmöglichkeiten generativer KI im Produktentstehungsprozess: Wie verändert generative KI den Ingenieurberuf? ZWF – Zeit-schrift für wirtschaftlichen Fabrikbetrieb, 120(5), 347-351. https://doi.org/10.1515/zwf-2025-1043

**(Moosbrugger & Kelava, 2012)**

Moosbrugger, H., & Kelava, A. (2012). Testtheorie und Fragebogenkonstruktion (2., überarbeitete und erweiterte Auflage). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-642-20072-4

**(Müller et. al., 2021)**

Müller, J. M., Buliga, O., & Voigt, K.-I. (2021). The role of absorptive capacity and innovation strategy in the design of Industry 4.0 business models: A comparison between SMEs and large enterprises. European Management Journal, 39(3), 333–343. https://doi.org/10.1016/j.emj.2020.01.002

**(Page et. al., 2021)**

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting system-atic reviews. BMJ, 372, n71. https://doi.org/10.1136/bmj.n71

**(Parikh et. al., 2023)**

Parikh, N. A. (2023). Empowering business transformation: Die positiven Auswirkungen und ethischen Überlegungen von generativer KI im Softwareproduktmanagement – Eine systema-tische Literaturrecherche. arXiv. https://doi.org/10.48550/arXiv.2306.04605

**(Patil et. al., 2017)**

Patil, S. R., Sirsikar, S. R., & Gholap, N. V. (2017). Product design and development: Phases and approach. International Journal of Engineering Research & Technology (IJERT), 6(7), 136–139. https://www.ijert.org/research/product-design-and-development-phases-and-approach-IJERTV6IS070136.pdf

**(Peckham et. Al., 2025)**

Peckham, O., Raines, J., Bulsink, E., Goudswaard, M., Gopsill, J., Barton, D., Nassehi, A., & Hicks, B. (2025). Artificial intelligence in generative design: A structured review of trends and opportunities in techniques and applications. Designs, 9(4), 79. https://doi.org/10.3390/designs9040079

**(Picazo-Sanchez et. al., 2024)**

Picazo-Sanchez, P., Ortiz-Martin, L. Analyse der Auswirkungen von ChatGPT in der Forschung. Appl Intell 54, 4172–4188 (2024). https://doi.org/10.1007/s10489-024-05298-0

**(Probst et. al., 2012)**

Probst, G., Raub, S., & Romhardt, K. (2012). Wissen managen: Wie Unternehmen ihre wertvollste Ressource optimal nutzen (6., überarb. und aktualisierte Aufl.). Springer Gabler. https://doi.org/10.1007/978-3-8349-4563-1

**(Ronge et. al., 2025)**

Ronge, R., Maier, M., & Rathgeber, B. (2025). Towards a definition of generative artificial intelligence. Philosophy & Technology, 38(31). https://doi.org/10.1007/s13347-025-00863-y

**(Shafiee, 2024)**

Shafiee, S. (2024). Integration of product and manufacturing design: A systematic literature review. Procedia CIRP, 121, 19–24. https://doi.org/10.1016/j.procir.2023.09.224

**(Shafiee, 2025)**

Shafiee, S. (2025). Generative AI manufacturing: A literature reviews of recent applications and future prospects. Journal of Manufacturing Systems, 132, 1-6. https://doi.org/10.1016/j.procir.2025.01.001

**(Statistischer Bundesamt, 2025)**

Statistisches Bundesamt. (14. Mai, 2025). Anzahl der Betriebe im Maschinenbau in Deutsch-land nach Beschäftigtengrößenklassen in den Jahren 2023 und 2024 [Graph]. In Statista. Zu-griff am 30. Oktober 2025, von https://de.statista.com/statistik/daten/studie/236301/umfrage/betriebsanzahl-im-deutschen-maschinenbau-nach-beschaeftigtengroessenklassen/

**(Steininger et. al., 2024)**

Steininger, S., Camci, H., & Fottner, J. (2024). Current state, potentials and challenges for the use of artificial intelligence in the early phase of product development: A survey. Proceed-ings of the 2024 IEEE International Conference on Industrial Engineering and Engineering Management. (IEEE) (pp.551-555). IEEE. https://doi.org/10.1109/IEEM62345.2024.10857061

**(Sommer, 2015)**

Sommer, L. (2015). Industrial revolution – Industry 4.0: Are German manufacturing SMEs the first victims of this revolution? Journal of Industrial Engineering and Management, 8(5), 1512–1532. https://doi.org/10.3926/jiem.1470

**(Ulich, 2013)**

Ulich, E. (2013). Arbeitssysteme als soziotechnische Systeme – eine Erinnerung. Psychologie des Alltagshandelns / Psychology of Everyday Activity, 6(1), 2–11. Innsbruck University Press.

**(Toubia, 2025)**

Toubia, O. (2025, April 8). How gen AI is transforming market research. Columbia Business School – Digital Future. https://business.columbia.edu/insights/digital-future/ai/generative-ai-market-research?utm_source=chatgpt.com

**(Tourangeau et. Al., 2000)**

Tourangeau, R., Rips, L. J., & Rasinski, K. (2000). The psychology of survey response. Cambridge University Press. https://doi.org/10.1017/CBO9780511819322

**(Turing, 1950)**

Turing, A. M. (1950). Computing machinery and intelligence. Mind, 59(236), 433-460. https://www.cs.mcgill.ca/~dprecup/courses/AI/Materials/turing1950.pdf

**(Forsa-Institute, 2025)**

TÜV-Verband. (2025, März 12). Studie zur Nutzung von Künstlicher Intelligenz in Deutschland – Wie sich Nutzungsverhalten und Wahrnehmung von KI verändert haben [Online-Umfrage: 16.–24. Oktober 2024 unter 1 001 Personen im Auftrag des TÜV-Verbands, durchgeführt von Forsa GmbH]. Initiative Markt- und Sozialforschung e. V. / Deutschlands Markt- und Sozialforscher. https://www.deutschlands-marktforscher.de/studie-zur-nutzung-von-kuenstlicher-intelligenz-in-deutschland/

**(Wang, 2019)**

Wang, P.-E. (2019). On defining artificial intelligence. Journal of Artificial Intelligence & Society, 5(1), 23-38. https://doi.org/10.2478/jagi-2019-0002

**(Wecke, 2024)**

Wecke, B. (2024). Grundlagen der generativen KI. In Wachstum durch den Einsatz von gene-rativer KI (Essentials). Springer Gabler, Wiesbaden. https://doi.org/10.1007/978-3-658-44041-1

**(White et. al., 2023)**

White, J., Fu, Q., Hays, S., Sandborn, M., Olea, C., Gilbert, H., Elnashar, A., Spencer-Smith, J., & Schmidt, D. C. (2023). A prompt pattern catalog to enhance prompt engineering with ChatGPT [Preprint]. ResearchGate. https://www.researchgate.net/publication/368716245_A_Prompt_Pattern_Catalog_to_Enhance_Prompt_Engineering_with_ChatGPT

**(Vaswani et. al., 2017)**

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.

N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In Advances in Neural Information Pro-cessing Systems (Vol. 30). Curran Associates, Inc. https://doi.org/10.48550/arXiv.1706.03762

**(Venkatesh et. Al., 2003)**

Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. MIS Quarterly, 27(3), 425–478. https://doi.org/10.2307/30036540

**(Zhang et. al., 2024)**

Zhang, T., Ladhak, F., Durmus, E., Liang, P., McKeown, K., & Hashimoto, T. B. (2024). Benchmarking large language models for news summarization. Transactions of the Association for Computational Linguistics, 12, 39–57. https://doi.org/10.1162/tacl_a_00632

## Anhang A: Variablenverzeichnis / Kodierung

Themenblock 1: „Demografie & Kontext“

| Theoretisches Konstrukt | Variabel | ID | Fragen-typ | Antwort-format | Skalenni-veau | Variab-lentyp |
|---|---|---|---|---|---|---|
| *Generationszugehörig-keit / Alterseffekt* | Alter | K102 | Single Choice | 18-24/25-29/30-34/35-45/>45 | Ordinal | kategorial geordnet |
| *Geschlechtsspezifische Unterschiede* | Geschlecht | K103 | Single Choice | männlich/weib-lich/divers | Nominal | kategorial |
| *Regionale Effekte* | Arbeitsregion | K104 | Drop - down | 16 Bundesländer (DE) | Nominal | kategorial |
| *Branchenspezifischer Einfluss* | Branche | K105 | Single Choice + Freitext | 4 Hauptbran-chen + Sonstiges | Nominal | kategorial |
| *Funktionale Tätigkeit im Arbeitskontext* | Rolle | K106 | Multiple Choice + Freitext | vordefinierte Rollen + Sonsti-ges | Nominal | kategorial |
| *Erfahrungsgrad / Be-rufliche Seniorität* | Berufserfah-rung | K107 | Single Choice | 0-2/3-5/6-10/>10/k.A. | Ordinal | kategorial geordnet |
| *Organisationsstruktur / Ressourcenumfang* | Unternehmens-größe | K108 | Single Choice | <50 / 50-100 / 500-1000 / k.A. | Ordinal | kategorial geordnet |

| Kodierung / (Numerische Zuordnung) |
|---|
| 1 = 18-24; 2 = 25-29; 3 = 30-34; 4 = 35-45; 5 = >46 |
| 1 = männlich; 2 = weiblich; 3 = divers |
| 1 = Badem-Württemberg, 2 = Bayern; 3 = Berlin; 4 = Brandenburg; 5 = Bremen; 6 = Hamburg; 7 = Hessen; 8 = Mecklen-burg-Vorpommern; 9 = Niedersachen; 10 = Nordrhein-Westfalen; 11 = Rheinland-Pfalz; 12 = Saarland; 13 = Sachsen; 14 = Sachen-Anhalt; 15 = Schleswig-Holstein; 16 = Thüringen |
| 1 = Maschinenbau; 2 = Automotiv; 3 = Energie; 4 = Elektrotechnik; 5 = Luft und Raumfahrt; 6 = Eigene Angabe; |
| 1 = Entwicklung; 2 = Konstruktion; 3 = Qualität; 4 = Fertigung; 5 = Eigene Angabe |
| 1 = 0-2; 2 = 3-5; 3 = 6-10; 4 = >10; 5 = k.A. |
| 1 = <50; 2 = 50-500; 3 = 500-1000; 4 = >1000; 5 = k.A. |

Themenblock 2: „Nutzungsstatus & Häufigkeit“

| **Theoretisches Konstrukt** | **Variabel** | **ID** | **Fragen-typ** | **Antwort-format** | **Skalenni-veau** | **Variab-lentyp** |
|---|---|---|---|---|---|---|
| *Technologieadoption / Anwendungsstauts* | Nutzungsstatus | K202 | Single Choice (Likert - System) | 1 = nie, 2 = monatlich, 3 = wöchentlich, 4 = mehrmals pro Woche, 5 = täglich | Nominal (Dichotom) | kategorial (binär) |
| *Nutzungsintensität generativer KI* | Nutzungshäufigkeit | K202 | Single Choice (Likert - System) | 1 = nie, 2 = monatlich, 3 = wöchentlich, 4 = mehrmals pro Woche, 5 = täglich | Verhältnis-skaliert | metrisch |
| *Anwendungsvielfalt* | Tool-Breite | K204 | Multiple Choice + Freitext | Vordefinierte Tool Anwendungen + individuelle Ergänzung | Intervallska-liert | metrisch |
| *Verhaltensintention zur Technologieadoption* | Nutzungsabsicht | K205 | Single Choice (Likert - System) | 1 = sehr unwahrscheinlich bis 5 = sehr wahrscheinlich | Ordinal | kategorial geordnet |
| *Hemmfaktoren / Nutzungshindernisse* | Barriere | K206 | Multiple Choice + Freitext | Vordefinierte Gründe + individuelle Ergänzung | Nominal | kategorial |

| **Kodierung / (Numerische Zuordnung)** |
|---|
| 1 = Nicht-Nutzer: innen; 2;3;4;5 = Nutzer: innen |
| 1 = 0; 2 = 2; 3 = 4; 4 = 12; 5 = 25 |
| 1 = Chat GPT; 2 = Google Gemini; 3 = Microsoft Copilot; 4 = Claude; 5 = Unternehmensintern; 6 = Eigene Angabe |
| 1 = sehr unwahrscheinlich; 2 = eher unwahrscheinlich; 3 = teils/teils; 4 = eher wahrscheinlich; 5 = sehr wahrscheinlich |
| 1 = kein klarer Nutzen für meine Arbeit; 2 = Datenschutz / Vertraulichkeit; 3 = Fehlender Zugang / Technische Hürde; 4 = Ablehnende Team- / Führungskultur; 5 = Eigene Angabe; *(1/0); 1 = trifft zu; 0 = trifft nicht zu* |

Themenblock 3:“Einsatzfelder generativer KI“ (Funktionssicht)

| **Theoretisches Konstrukt** | **Variabel** | **ID** | **Fragen-typ** | **Antwort-format** | **Skalenni-veau** | **Variab-lentyp** |
|---|---|---|---|---|---|---|
| *Kreative Konstruktive Aufgabenbearbeitung* | Ideengenerie-rung / Konzept-entwicklung | K302 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Information Beschaf-fung* | Recherche / Zu-sammenfas-sung | K303 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Technische Aufgaben-automatisierung* | Programmie-rung / Skripten / Fehlersuche | K304 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Informationsorgani-sierung* | CAD / CAE Unterstützung | K305 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Wissensspeicherung* | Dokumentation / Protokolle | K306 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Informationsaustausch* | Kommunika-tion / E-Mails | K307 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Sprachliche Vermitt-lung* | Übersetzung / Mehrsprachig-keit | K308 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Qualitätssicherung / Risikokontrolle* | Qualität- / Si-cherheitsre-views | K309 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |
| *Wissensspeicherung* | Wissensma-nagement | K310 | Single Choice (Li-kert-System) | 1 = nie; bis 5 = sehr häufig | Ordinal | quasi-met-risch |

| **Kodierung / (Numerische Zuordnung)** |
|---|
| 1 = nie; 2 = selten; 3 = gelegentlich; 4 = häufig; 5 = sehr häufig |

Themenblock 3: „Einsatzfelder generativer KI“ (Prozesssicht)

| **Theoretisches Konstrukt** | **Variabel** | **ID** | **Fragen-typ** | **Antwort-format** | **Skalenni-veau** | **Variab-lentyp** |
|---|---|---|---|---|---|---|
| *Prozessintegration* | PEP-Phase | K312 | Multiple-Choice (min. 2) | 1 = Produktpla-nung, 2 = Ent-wicklung und Konstruktion, 3 = Arbeitsvorbe-reitung, 4 = Pro-duktion, 5 = Serviceplanung | Nominal | kategorial |
| *Zielmotivation der KI-Nutzung* | Priorität der Nutzung | K313 | Ranking (Drag & Drop) | vordefinierte Zielmotivatio-nen | Ordinal | kategorial (geordnet) |
| *Information Beschaf-fung* | Recherche / Zusammenfas-sung | K314 | Freitextfeld | freie Beschrei-bung | _ | qualitativ |

| **Kodierung / (Numerische Zuordnung)** |
|---|
| 1 = Produktplanung, 2 = Entwicklung und Konstruktion, 3 = Arbeitsvorbereitung, 4 = Produktion, 5 = Serviceplanung; *(1/0); 1 = trifft zu; 0 = trifft nicht zu* |
| 1 = höchste Priorität; 2 = zweite Priorität; …; n = niedrigste Priorität |
| keine numerische Kodierung; qualitative Auswertung der Freitextangaben |

Themenblock 4: „Subjektiver Kenntnisstand“

| **Theoretisches Konstrukt** | **Variabel** | **ID** | **Fragen-typ** | **Antwort-format** | **Skalenni-veau** | **Variab-lentyp** |
|---|---|---|---|---|---|---|
| *Selbstwirksamkeit / wahrgenommen Kompetenz im Umgang mit generativer KI* | Kompetenz-Score | Aggre-gierter Kompe-tenz-Score (Mittel-wert aus 6 Items; K402 - K407) | Single Choice (Lik-ert-System, fünfstufig) | 1 = stimme gar nicht zu; bis 5 = stimme voll-kommen zu | Intervallska-liert | metrisch |

| **Kodierung / (Numerische Zuordnung)** |
|---|
| numerische Mittelwertbildung der Items K402–K407 Wertebereich (1–5) |

Themenblock 5: „Objektiver Kenntnisstand“

| **Theoretisches Konstrukt** | **Variabel** | **ID** | **Fragen-typ** | **Antwort-format** | **Skalenni-veau** | **Variab-lentyp** |
|---|---|---|---|---|---|---|
| *Tatsächliches Wissen der Befragten. Messung der technologischen Kompetenz* | Quiz-Score | Aggre-gierter Quiz-Score (Mittel-wert aus 4 Items; K502-K505) | Single Choice (Li-kert-System, dreistufig) | 1 = Stimme nicht zu; 2 = Teils/Teils; 3 = Stimme zu | Verhältnis-skaliert | metrisch |

| **Kodierung / (Numerische Zuordnung)** |
|---|
| numerische Mittelwertbildung der Items K502–K505 Wertebereich (1–3) |

Themenblock 6: „Einsatzpotenzial im Arbeitskontext“

| **Theoretisches Konstrukt** | **Variabel** | **ID** | **Fragentyp** | **Antwortformat** | **Skalenniveau** | **Variablentyp** |
|---|---|---|---|---|---|---|
| *Wahrgenommene Nützlichkeit (Einsatzpotenzial) generativer KI zur Leistungssteigerung und Effizienz im Arbeitsalltag* | Nutzen-Score | Aggregierter Nutzen-Score (Mittelwert aus 4 Items; K602-K605) | Single Choice (Likert-System, fünfstufig) | 1 = stimme gar nicht zu; bis 5 = stimme vollkommen zu | Intervallskaliert | metrisch |

| **Kodierung / (Numerische Zuordnung)** |
|---|
| numerische Mittelwertbildung der Items K602-K605 Wertebereich (1–5) |

Themenblock 7: „Vertrauen & Risiko“

| **Theoretisches Konstrukt** | **Variabel** | **ID** | **Fragentyp** | **Antwortformat** | **Skalenniveau** | **Variablentyp** |
|---|---|---|---|---|---|---|
| *Zuverlässigkeit generativer KI* | Vertrauens-Score | Aggregierter Nutzen-Score (Mittelwert aus 4 Items; K702-K705) | Single Choice (Likert-System, fünfstufig) | 1 = stimme gar nicht zu; bis 5 = stimme vollkommen zu | Intervallskaliert | metrisch |
| *Wahrnehmung potenzieller Risiken* | Risiko-Score | Aggregierter Nutzen-Score (Mittelwert aus 5 Items; K706-K710) | Single Choice (Likert-System, fünfstufig) | 1 = stimme gar nicht zu; bis 5 = stimme vollkommen zu | Intervallskaliert | metrisch |

| **Kodierung / (Numerische Zuordnung)** |
|---|
| **numerische Mittelwertbildung der Items K702-K705 Wertebereich (1–5)** |
| **numerische Mittelwertbildung der Items K706-K710 Wertebereich (1–5)** |

**Eidesstattliche Erklärung**

Ich versichere an Eides statt durch meine Unterschrift, dass ich die vorliegende Arbeit selbständig und nur unter Angabe der genutzten Hilfsmittel angefertigt und alle Stellen, die ich wörtlich oder annähernd wörtlich aus Veröffentlichungen entnommen habe, als solche kenntlich gemacht habe, mich auch keiner anderen als der angegebenen Literatur oder sonstiger Hilfsmittel bedient habe. Zusätzlich versichere ich, dass ich beim Einsatz von generativen IT-bzw. KI-Werkzeugen und/oder KI-gestützten Schreibwerkzeugen diese als Liste mit ihrem Produktnamen, Angaben zu genutzten Funktionen der Software und zum Nutzungsumfang vollständig aufgeführt habe. Wörtliche sowie paraphrasierende Übernahmen aus Ergebnissen dieser Werkzeuge habe ich analog zu anderen Quellenangaben gekennzeichnet.

Des Weiteren hat die Arbeit in dieser oder ähnlicher Form noch keiner anderen Prüfungsbehörde vorgelegen.

Düsseldorf, 31.10.2025

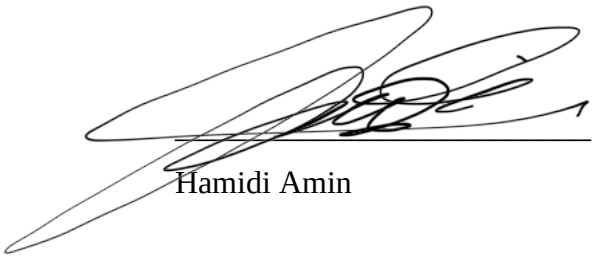

Hamidi Amin