

DOCTORAL (PhD) DISSERTATION

CEDRIC BARTELT MSc

University of Sopron

Sopron

2026

University of Sopron
István Széchenyi Economics and Management Doctoral School

**ENTWICKLUNG EINES IMPLEMENTIERUNGSFRAMEWORKS
FÜR DEN UNTERNEHMENSWEITEN EINSATZ GENERATIVER
KÜNSTLICHER INTELLIGENZ IM DEUTSCHEN MITTELSTAND**

Doctoral (PhD) dissertation

Written by:
Cedric Bartelt MSc

Supervisors:
Prof. Dr. Koloszar László
Prof. Dr. Carolin Tewes

Sopron

2026

**ENTWICKLUNG EINES IMPLEMENTIERUNGSFRAMEWORKS FÜR DEN UN-
TERNEHMENSWEITEN EINSATZ GENERATIVER KÜNSTLICHER INTELLI-
GENZ IM DEUTSCHEN MITTELSTAND**

Dissertation to obtain a PhD degree

Written by:

Cedric Bartelt MSc

Prepared by the University of Sopron

István Széchenyi Economic and Management Doctoral School

within the framework of the Business Economics & Management Programme

Supervisors: Prof. Dr. Koloszár László

Prof. Dr. Carolin Tewes

The supervisors have recommended the evaluation of the dissertation be accepted: yes / no

1st supervisor signature

2nd supervisor signature

The evaluation has been recommended for approval by the reviewers (yes/no)

1. judge: Dr. _____ yes/no

(signature)

2. judge: Dr. _____ yes/no

(signature)

Result of the public dissertation defense: _____ %

Sopron, 20 ____ year _____ month ____ day

Chairperson of the Judging Committee

Qualification of the PhD degree: _____

UDHC Chairperson

INHALTSVERZEICHNIS

Tabellenverzeichnis	VIII
Abbildungsverzeichnis	IX
Abkürzungsverzeichnis	X
Abstrakt	XI
1 Einleitung	1
1.1 Relevanz und Problemstellung	1
1.2 Forschungsleitende Fragestellung und Zielsetzungen	4
1.3 Struktureller Aufbau	6
2 Stand der aktuellen Forschung	9
2.1 Systematik der Literaturrecherche in Anlehnung an PRISMA-Methodik	9
2.1.1 Zielsetzung und methodische Orientierung	9
2.1.2 Abgrenzung des Forschungsfeldes	9
2.1.3 Suchstrategie und Datenbankauswahl	10
2.1.4 Auswahl und Begründung von Ein- und Ausschlusskriterien	11
2.1.5 Anwendung und Ergebnisse der systematischen Literaturrecherche	12
2.2 Generative KI: Begriffsbestimmung und technologische Grundlagen	14
2.2.1 Begriffliche Einordnung und Definition generativer KI	14
2.2.2 Technologische Grundlagen generativer KI	15
2.2.3 Relevanz und Integration von KI-Anwendungen in Unternehmen	17
2.3 Forschungsstand zum Implementierungsprozess von KI-Anwendungen	19
2.3.1 Prozessmodelle und Phasen der KI-Implementierung	19
2.3.2 Strategische Implikationen und Governance der KI-Implementierung	21
2.3.3 Basistechnologien und technologische Infrastruktur	23
2.3.4 Hemmnisse der KI-Implementierung	25
2.4 Bewertungskriterien und Erfolgsfaktoren der KI-Implementierung	26
2.5 Entwicklung und Operationalisierung von KI-Roadmaps	28
3 Theoretische und konzeptionelle Verankerung	30
3.1 Systematik der Theorieauswahl und der konzeptionellen Integration	30
3.1.1 Erläuterung der Kategorisierungscharakteristika	30
3.1.2 Ableitung von Bewertungskriterien	31
3.2 Erster Schritt: Identifikation der theoretischen Basis	33
3.3 Zweiter Schritt: Kategorisierung und Bewertung der theoretischen Basis	35
3.3.1 Kerntheorien und ihre Bewertung für die Framework-Entwicklung	35
3.3.2 Kontexttheorien und ihre Bewertung für die wissenschaftliche Verankerung	38

4	Methodik.....	41
4.1	Systematik des Forschungsdesigns und theoretische Fundierung.....	41
4.2	Phase 1: Rekrutierung und Datensammlung	45
4.2.1	Sampling-Strategie	45
4.2.1.1	Begründung zur Purposive-Sampling-Methode	45
4.2.1.2	Definition und Abgrenzung der Zielpopulation	45
4.2.1.3	Bestimmung der Sampling-Kriterien	46
4.2.2	Scoring-Modell zur Expertisebewertung und Auswahl von Expert*innen	47
4.2.2.1	Ableitung des Scoring-Modells zur Expertisebewertung.....	47
4.2.2.2	Entwicklung und Definition der Bewertungskriterien	47
4.2.2.3	Gewichtung der Bewertungskriterien.....	48
4.2.2.4	Skalierung der Bewertungskriterien	49
4.2.2.5	Festlegung der Schwellenwerte und Interpretation	50
4.2.3	Rekrutierungsstrategie	51
4.2.3.1	Zielsetzung und methodische Einordnung	51
4.2.3.2	Rekrutierungskanäle und praktische Umsetzung	52
4.2.3.3	Stichprobengröße und -zusammensetzung	53
4.2.4	Expert*inneninterviews	54
4.2.4.1	Entwicklung des halbstrukturierten Interviewleitfadens	54
4.2.4.2	Durchführung Pretest und Optimierung Interviewleitfaden.....	55
4.2.4.3	Durchführung und Dokumentation der Expert*inneninterviews	56
4.2.5	Ergänzende Dokumentenanalyse.....	57
4.2.5.1	Entwicklung und Definition der Ein- und Ausschlusskriterien.....	57
4.2.5.2	Systematische Podcastrecherche	59
4.3	Phase 2: Entwicklung Erstentwurf Implementierungsframeworks.....	60
4.3.1	Qualitative Inhaltsanalyse nach Kuckartz (induktiv) – Expert*inneninterviews	60
4.3.1.1	Datenbasis und Transkription.....	60
4.3.1.2	Analytisches Vorgehen zur qualitativen Inhaltsanalyse.....	61
4.3.1.3	Qualitätssicherung und Reflexion zum induktiven Ansatz	64
4.3.2	Qualitative Inhaltsanalyse nach Kuckartz (deduktiv-induktiv) – Dokumentenanalyse.....	64
4.3.2.1	Datenbasis und Transkription.....	64
4.3.2.2	Hinweis zum analytischen Vorgehen zur qualitativen Inhaltsanalyse	64
4.3.2.3	Qualitätssicherung und Reflexion zum deduktiv-induktiven Ansatz.....	65
4.3.3	Ableitung des Implementierungsframeworks.....	66

4.3.3.1	Zielsetzung und methodische Einordnung	66
4.3.3.2	Festlegung methodischer Schritte zur Framework-Entwicklung	67
4.3.3.3	Qualitätssicherung und Reflexion der Framework-Entwicklung	68
4.4	Phase 3: Validierung und Finalisierung Implementierungsframework.....	69
4.4.1	Member Checking	69
4.4.1.1	Zielsetzung und methodische Einordnung	69
4.4.1.2	Auswahl und Rekrutierung der Validierungsexpert*innen	69
4.4.1.3	Entwicklung des halbstrukturierten Interviewleitfadens	70
4.4.1.4	Durchführung Pretest und Optimierung Interviewleitfaden.....	71
4.4.1.5	Durchführung und Dokumentation des Member Checkings.....	72
4.4.2	Framework Analysis.....	73
4.4.2.1	Zielsetzung und methodische Einordnung	73
4.4.2.2	Analytisches Vorgehen zur Framework Analysis	74
4.4.2.3	Dokumentation des Auswertungsprozesses	74
4.5	Retrospektive: Qualitative Gütekriterien und Praxisanforderungen	75
4.5.1	Ziel und Stellenwert der retrospektiven Betrachtung	75
4.5.2	Anwendung qualitativer Gütekriterien im Forschungsprozess	76
4.5.2.1	Transparenz und Nachvollziehbarkeit	76
4.5.2.2	Validität und Triangulation	76
4.5.2.3	Kohärenz und Transferierbarkeit.....	77
4.5.2.4	Herausforderungen im Forschungsprozess.....	77
5	Ergebnisse der empirischen Untersuchung und Entwicklung des Implementierungsframeworks	79
5.1	Systematik der Ergebnisdarstellung und Frameworkentwicklung.....	79
5.2	Ergebnisse der Expert*inneninterviews und Dokumentenanalyse	80
5.2.1	Prozessbeschreibende Kategorien	80
5.2.1.1	Problemidentifikation und Kontextanalyse (PROB-IMP).....	80
5.2.1.2	Konzeptionierung und Planung (KONZ-IMP).....	81
5.2.1.3	Prototyping und Pilotierung (PROT-IMP)	82
5.2.1.4	Integration und Rollout (INT-IMP).....	82
5.2.1.5	Evaluation und Skalierung (EVA-IMP)	83
5.2.2	Prozessbegleitende Kategorien.....	84
5.2.2.1	Implementierungsstrategie und übergeordnete Zielsetzungen (STRAT) 84	
5.2.2.2	Technologieeinsatz und Systemintegration (TECH).....	85
5.2.2.3	Erfolgsmessung und Bewertungskriterien (EVAL)	86

5.2.2.4	Zukünftige Entwicklungen und KI-Roadmap (FUT)	87
5.2.3	Dissenspunkte und kontroverse Ergebnisse	88
5.2.4	Praxisrelevante Implikationen und Brücke zur Framework-Entwicklung	91
5.3	Ableitung Erstentwurf Implementierungsframework	93
5.3.1	Problemdefinition und Zielsetzung	93
5.3.2	Konzeptmapping.....	96
5.3.2.1	Mapping prozessbeschreibende Kategorien	96
5.3.2.2	Mapping prozessbegleitende Kategorien	96
5.3.2.3	Darlegung Querschnittserkenntnisse und Wechselwirkungen	98
5.3.3	Konsolidierung prozessbeschreibender und prozessbegleitender Kategorien.....	99
5.3.3.1	Prozessphase 1: Problemidentifikation und Kontextanalyse.....	99
5.3.3.2	Prozessphase 2: Konzeptionierung und Planung.....	102
5.3.3.3	Prozessphase 3: Prototyping und Pilotierung	104
5.3.3.4	Prozessphase 4: Integration und Rollout	105
5.3.3.5	Prozessphase 5: Evaluation und Skalierung	107
5.4	Ergebnisse der Validierungsgespräche.....	109
5.4.1	Validierung der Plausibilität und Realisierbarkeit.....	109
5.4.2	Darlegung der Dissenspunkte und kontroversen Ergebnisse	112
5.5	Weiterentwicklung des Implementierungsframeworks.....	114
5.5.1	Ableitung struktureller und inhaltlicher Optimierungsvorschläge	114
5.5.2	Bewertung der Optimierungsvorschläge und Beitrag zur Weiterentwicklung des Implementierungsframeworks.....	119
5.6	Theoretische Adaption des Implementierungsframeworks am Marketingprozess	125
5.6.1	Auswahl und theoretische Einordnung des Anwendungsfalls	125
5.6.2	Erläuterung des Anwendungsszenarios	126
5.6.3	Anwendung auf Prozessphase 1: Problem- und Chancenidentifikation.....	127
5.6.4	Anwendung auf Prozessphase 2: Konzeptionierung und Planung	128
5.6.5	Anwendung auf Prozessphase 3: Prototyping oder Pilotierung	129
5.6.6	Anwendung auf Prozessphase 4: Integration und Rollout.....	130
5.6.7	Anwendung auf Prozessphase 5: Evaluation und Weiterentwicklung	131
6	Diskussion der Untersuchungsergebnisse.....	133
6.1	Zentrale Ergebnisse der Forschungsarbeit und Beantwortung der Forschungsfragen	133
6.2	Neue wissenschaftliche Ergebnisse und Beitrag der Forschungsarbeit	136
6.3	Handlungsempfehlungen für die Unternehmenspraxis.....	138

6.3.1	Strategische Handlungsempfehlungen entlang des Implementierungsframeworks	138
6.3.2	Operative Handlungsempfehlungen entlang des Implementierungsframeworks	139
6.4	Reflexion der Forschungsmethodik	140
6.5	Forschungsausblick	142
	Zusammenfassung	145
	Anhang	147
	Literaturverzeichnis	147
	Anhang A: Erstentwurf Interviewleitfaden (interne Perspektive).....	162
	Anhang B: Erstentwurf Interviewleitfaden (externe Perspektive)	164
	Anhang C: Finalversion Interviewleitfaden nach Pretest (interne Perspektive).....	166
	Anhang D: Finalversion Interviewleitfaden nach Pretest (externe Perspektive).....	168
	Anhang E: Interviewprotokolle Expert*inneninterviews	170
	Anhang F: MAXQDA	171
	Anhang G: Erstentwurf Leitfaden Validierungsgespräche.....	172
	Anhang H: Finalversion Leitfaden Validierungsgespräche	175
	Anhang I: Transkripte der Expert*inneninterviews, Podcastfolgen und Validierungsgespräche	177
	Anhang J: Erstentwurf Implementierungsframework	178
	Anhang K: Datenmatrix Framework Analysis	179
	Anhang L: Finalversion Implementierungsframework	180
	Anhang M: Glossar.....	181
	Anlagen.....	184
	Declaration on Identity	184
	Legal Declaration	185
	Widmung	186

TABELLENVERZEICHNIS

Tabelle 1: Ableitung Forschungsfragen und Zielsetzungen.....	5
Tabelle 2: Überblick zum strukturellen Aufbau der Forschungsarbeit	8
Tabelle 3: Verwendete Schlagwortkombination innerhalb der Literatursuche.....	11
Tabelle 4: Ein- und Ausschlusskriterien der Literaturanalyse	12
Tabelle 5: Bewertungskriterien zur Theorieauswahl.....	31
Tabelle 6: Überblick und Beitrag der Kerntheorien zur Framework-Entwicklung.....	38
Tabelle 7: Überblick und Beitrag der Kerntheorien zur Framework-Entwicklung.....	40
Tabelle 8: Bewertungskriterien für das Scoring-Modell zur Expert*innenauswahl	48
Tabelle 9: Gewichtung der Bewertungskriterien im Scoring-Modell	49
Tabelle 10: Sechsstufige Skala zur Bewertung der Expertise	50
Tabelle 11: Definition der Expertisekategorien und Schwellenwerte	51
Tabelle 12: Ein- und Ausschlusskriterien für die Auswahl der Podcasts.....	58
Tabelle 13: Implikationen und Anforderungen an das Implementierungsframework	91
Tabelle 14: Zusammenfassung der Querschnittserkenntnisse und abgeleiteten Wechselwirkungen	99
Tabelle 15: Zusammenfassung der Validierungsgespräche	110
Tabelle 16: Analysierte Dissenspunkte und deren Ergebnisse.....	112
Tabelle 17: Zusammenfassung der strukturellen Optimierungsvorschläge	115
Tabelle 18: Zusammenfassung der inhaltlichen Optimierungsvorschläge.....	117
Tabelle 19: Übersicht der wissenschaftlichen Beiträge und neuen wissenschaftlichen Ergebnisse.....	137
Tabelle 20: Übersicht von Hypothesen für weiterführende Forschungsarbeiten	144

ABBILDUNGSVERZEICHNIS

Abbildung 1: PRISMA-Flowchart ein- und ausgeschlossener Studien	13
Abbildung 2: Phasen der KI-Implementierung	20
Abbildung 3: Phase 1 des Forschungsprozesses	42
Abbildung 4: Phase 2 des Forschungsprozesses	43
Abbildung 5: Phase 3 des Forschungsprozesses	44
Abbildung 6: Ergebnisse des Rekrutierungsprozesses	52
Abbildung 7: PRISMA-Flowchart ein- und ausgeschlossener Podcasts.....	60
Abbildung 8: Ablaufschema der inhaltlich-strukturierenden Inhaltsanalyse	61
Abbildung 9: Prozessschritte zur Ableitung des Implementierungsframeworks	67
Abbildung 10: Erstentwurf des Implementierungsframeworks	100
Abbildung 11: Gegenüberstellung Erstentwurf (oben) und Finalversion des Implementierungsframeworks (unten).....	124

ABKÜRZUNGSVERZEICHNIS

DSR	Design Science Research
EF	ergänzende Forschungsfragen
EVAL	Erfolgsmessung und Wirkungen
FUT	KI-Roadmap und Zukunftsausrichtung
GAN	Generative Adversarial Network
KI	Künstliche Intelligenz
KMU	kleine und mittelständische Unternehmen
KPI	Key Performance Indicator
LF	leitende Forschungsfrage
LLM	Large Language Models
PIM	Produktinformations-Management-Systeme
PoC	Proof-of-Concept
ML	maschinelles Lernen
ROI	Return on Investment
SEA	Suchmaschinenwerbung
SEO	Suchmaschinenoptimierung
STRAT	Implementierungsstrategie und Steuerungslogiken
TAM	Technology-Acceptance-Model
TECH	Technologieauswahl, Deployment-Optionen und Integrationsgrad
TOE	Technology-Organization-Environment
VAE	Variational Autoencoders

ABSTRAKT

Für die systematische Implementierung generativer Künstlicher Intelligenz in kleinen und mittelständischen Unternehmen entwickelt diese Dissertation ein prozessorientiertes und empirisch validiertes Framework. Die praktische Anwendbarkeit des Frameworks wird anhand eines Marketing-Anwendungsfalls demonstriert. Damit beantwortet die Arbeit die zentrale Forschungsfrage, wie sich der Implementierungsprozess für den deutschen Mittelstand gestalten lässt und welche strategischen Ansätze sowie Basistechnologien dabei genutzt werden können. Grundlage bildete ein dreistufiger qualitativ-explorativer Ansatz: Zunächst wurde aus 39 Expert*inneninterviews und einer Dokumentenrecherche mittels qualitativer Inhaltsanalyse ein erster Framework-Entwurf entwickelt. Dieser wurde anschließend durch Validierungsgespräche mit den Expert*innen (Member Checking) geprüft und schlussendlich finalisiert. Das Ergebnis dieses Prozesses ist ein validiertes Implementierungsframework. Dieses teilt den Einführungsprozess in fünf Phasen unter: (1) Identifikation von Problemen und Chancen, (2) Konzeptionierung und Planung, (3) Prototyping oder Pilotierung, (4) Integration und Rollout sowie (5) Evaluation und Weiterentwicklung. Es bietet dabei mehr als eine rein technische Anleitung, indem es strategische, technologische, organisatorische und kulturelle Dimensionen miteinander verknüpft. Der Implementierungserfolg ist dabei an drei strategische Voraussetzungen geknüpft: eine symbiotische Steuerungslogik, eine klare Technologie- und Datenstrategie und die kontinuierliche Befähigung der Mitarbeitenden. Der primäre wissenschaftliche Beitrag dieser Forschungsarbeit liegt in der Entwicklung eines der ersten empirisch validierten Frameworks, das die Implementierung generativer Künstlicher Intelligenz speziell für kleine und mittelständische Unternehmen strukturiert. Es schlägt eine Brücke zwischen etablierten Adoptionstheorien und dem konkreten Handlungsbedarf in der Praxis, indem es ein direkt anwendbares, phasenbasiertes Prozessmodell bereitstellt. Für Unternehmen dient das Framework als praktischer Leitfaden, der eine an die individuellen Gegebenheiten angepasste Vorgehensweise ermöglicht. Zukünftige Forschung kann hieran anknüpfen, indem sie branchenspezifische Adaptionen entwickelt oder die identifizierten Erfolgsfaktoren quantitativ überprüft.

Schlüsselwörter

Generative Künstliche Intelligenz, kleine und mittlere Unternehmen, KMU, Implementierungsrahmen, KI-Adoption, digitale Transformation, Marketing, qualitative Forschung

JEL-Codes: C80, D83, M31, L26, O30, O32

ABSTRACT

This dissertation develops a process-oriented and empirically validated framework for the systematic implementation of generative Artificial Intelligence in small and medium-sized enterprises. The framework's practical applicability is demonstrated through a marketing use case. In doing so, this work answers the central research question of how the implementation process can be designed for the German Mittelstand and which strategic approaches and underlying technologies can be utilized. A three-stage qualitative approach provided the methodological foundation: First, an initial framework draft was developed from 39 expert interviews and a document analysis using qualitative content analysis. This draft was subsequently reviewed and finalized through validation interviews with the experts (member checking). The result of this process is a validated implementation framework that divides the implementation process into five phases: (1) Identification of Problems and Opportunities, (2) Conceptualization and Planning, (3) Prototyping or Piloting, (4) Integration and Rollout, and (5) Evaluation and Further Development. The framework offers more than purely technical guidance by integrating strategic, technological, organizational, and cultural dimensions. Implementation success depends on three strategic prerequisites: a symbiotic governance logic, a clear technology and data strategy, and the continuous enablement of employees. The primary scientific contribution of this work lies in the development of one of the first empirically validated frameworks that structures the implementation of generative Artificial Intelligence specifically for small and medium-sized enterprises. It bridges the gap between established adoption theories and the concrete need for action in practice by providing a directly applicable, phase-based process model. For companies, the framework serves as a practical guide that allows for an approach tailored to their individual circumstances. Future research can build on this by developing industry-specific adaptations or by quantitatively testing the identified success factors.

Keywords

Generative Artificial Intelligence, small and medium-sized enterprises, SMEs, implementation framework, AI adoption, digital transformation, Marketing, qualitative research

JEL-Codes: C80, D83, M31, L26, O30, O32

1 EINLEITUNG

1.1 Relevanz und Problemstellung

Die Entwicklung der Künstlichen Intelligenz (KI) hat in den vergangenen Jahren zu einem bedeutsamen Wandel in der technologischen Landschaft geführt. Während die Grundlagen bereits seit den 1950er Jahren erforscht werden, markiert die Entstehung und Verbreitung generativer KI einen Paradigmenwechsel in der Art, wie Unternehmen und Gesellschaft mit intelligenten Systemen interagieren (Al Naqbi et al., 2024; Cao et al., 2023; Feuerriegel et al., 2023). Ihre Fähigkeit, komplexe Inhalte wie Texte, Bilder und andere Medienformate zu erstellen, hat diese Technologie von einem experimentellen Forschungsprojekt zu einem praxistauglichen Werkzeug gewandelt, das grundlegende Geschäftsprozesse transformiert (Bengesi, El-Sayed, Sarker, Houkpati, Irungu, et al., 2024; Gozalo-Brizuela & Garrido-Merchán, 2023; W. X. Zhao et al., 2025).

Angesichts der gesellschaftlichen und wirtschaftlichen Relevanz steht die deutsche Wirtschaft vor der Herausforderung, ihre Position im internationalen Wettbewerb zu behaupten und zeitgleich die Potenziale digitaler Transformation durch generative KI zu erschließen (Gualandri & Kuzior, 2024; Peres et al., 2020). Aktuelle Studien belegen eine zunehmende KI-Adaption in deutschen Unternehmen. Während im Jahr 2024 laut Statistischem Bundesamt (2024b) noch 20 % der Unternehmen KI-Technologien nutzten – mit einer höheren Verbreitung bei Großunternehmen (48 %) gegenüber mittleren (28 %) und kleinen (17 %) –, zeichnen neuere Erhebungen für 2025 ein deutlich dynamischeres Bild. So verzeichnet das ifo Institut (2025) für 2025 eine Steigerung der Nutzungsquote auf 40,9 %, ausgehend von 27 % im Vorjahr. Diesen Aufwärtstrend bestätigen weitere aktuelle Erhebungen, die eine KI-Nutzung von 36 % (Bitkom e. V., 2025) bzw. 37 % (Institut der deutschen Wirtschaft, 2025) ausweisen. Dabei birgt die Implementierung Potenziale für Produktivitätssteigerungen und Innovationen, die sich unmittelbar auf die Wettbewerbsfähigkeit der deutschen Volkswirtschaft auswirken können (B. Li et al., 2017; Prasad Agrawal, 2024).

Besonders bedeutsam ist die Rolle kleiner und mittelständischer Unternehmen (KMU) in diesem Transformationsprozess. Der deutsche Mittelstand, der traditionell das Rückgrat der deutschen Wirtschaft bildet, umfasst rund 3,44 Millionen Unternehmen (Stand: 2023) und repräsentiert damit 99,2 % aller Unternehmen in Deutschland (ifM Bonn, 2024a). Mit 19,08 Millionen abhängig Beschäftigten (Stand: 2023), was einem Anteil von 53,1 % aller Beschäftigten entspricht, stellen KMU die zentrale Säule des deutschen Arbeitsmarktes dar

(ifM Bonn, 2024a). Ihre volkswirtschaftliche Bedeutung zeigt sich auch in ihrem Beitrag zur Nettowertschöpfung von 55,7 % (Stand: 2022) sowie am Gesamtumsatz von 28,0 % (Stand: 2023) (ifM Bonn, 2024b; Statistisches Bundesamt, 2024a). Ferner stellen KMU mit 69,4 % (Stand: 2023) den größten Anteil der Ausbildungsplätze bereit (ifM Bonn, 2024a). Trotz dieser zentralen Stellung sehen sich mittelständische Unternehmen bei der Implementierung generativer KI mit besonderen Herausforderungen konfrontiert, die von Ressourcenknappheit, also fehlenden finanziellen und zeitlichen Mitteln, über den Mangel an notwendiger Expertise und qualifizierten IT-Fachkräften bis hin zu Defiziten im Change-Management reichen (Mesloh, 2021; Rajaram & Tinguely, 2024). Hinzu kommen ausgeprägte digitale Kompetenzlücken innerhalb der Belegschaften, ein hoher Weiterbildungsbedarf sowie rechtliche und bürokratische Hürden wie Datenschutz- und Compliance-Anforderungen, die den Implementierungsprozess zusätzlich verlangsamen (Mesloh, 2021). Während Großunternehmen über umfangreiche Ressourcen und spezialisierte IT-Abteilungen verfügen, fehlen KMU häufig die Mittel für eine erfolgreiche Implementierung (Gupta, 2024; Oldemeyer et al., 2024; Schwaewe et al., 2024). Infolgedessen entsteht eine Diskrepanz zwischen den Potenzialen der Technologie und den Umsetzungsmöglichkeiten im Mittelstand, die eine gesellschaftliche sowie wirtschaftliche Herausforderung darstellt (Bettoni et al., 2021; Szedlak et al., 2021).

In mittelständischen Unternehmen können insbesondere Fachabteilungen wie das Marketing sowohl von den Potenzialen generativer KI profitieren als auch vor erheblichen Implementierungsherausforderungen stehen (Davenport et al., 2020; Haleem, Javaid, & Singh, 2022; Mikalef et al., 2021). Marketingabteilungen werden in die Lage versetzt, mit einem geringen Ressourcenaufwand umfangreich strukturierte und individualisierte Inhalte zu generieren sowie auf Basis datengestützter Analysen systematisch Kampagnenentscheidungen zu treffen und dadurch die Effizienz und Wirksamkeit ihrer Marketingmaßnahmen zu steigern (Gołąb-Andrzejak, 2023; Huang & Rust, 2021). Gleichzeitig erfordert die Integration organisatorische Anpassungen, neue Kompetenzprofile und veränderte Arbeitsabläufe (D. Kumar & Ratten, 2024).

Während die Unternehmenspraxis gegenwärtig an der Entwicklung und Umsetzung tragfähiger Implementierungskonzepte für generative KI arbeitet, zeigt sich parallel dazu, dass die wissenschaftliche Forschung noch nicht in ausreichendem Maße vorangeschritten ist (Oldemeyer et al., 2024; Sadiq et al., 2021). Trotz der offensichtlichen Relevanz für die

Unternehmenspraxis existieren Forschungslücken bezüglich der Implementierungserfahrungen mittelständischer Unternehmen (Kanbach et al., 2023; Schönberger, 2023). Es mangelt zudem an systematischen Untersuchungen darüber, wie KMU die Implementierung in der Praxis gestalten und welche Transformationsprozesse in Fachabteilungen wie dem Marketing erforderlich sind (Campbell et al., 2020; J. Chen et al., 2023). Umso bedeutsamer ist diese Forschungslücke, als dass sich die theoretischen Erkenntnisse über KI-Implementierung vorwiegend auf Großunternehmen oder allgemeine Betrachtungen beschränken, ohne die spezifischen Rahmenbedingungen und Herausforderungen des Mittelstands zu berücksichtigen.

Eine weitere Problemstellung liegt in der mangelnden technischen Expertise und den begrenzten Ressourcen. Aktuelle Studien belegen, dass mittelständische Unternehmen erhebliche Schwierigkeiten haben, generative KI aufgrund fehlender technischer Kompetenzen und unzureichender finanzieller Ressourcen in bestehende Geschäftsprozesse zu integrieren (Mesloh, 2021; Oldemeyer et al., 2024; Rajaram & Tinguely, 2024). Neben den bekannten technischen Herausforderungen bestehen bei der Implementierung auch organisatorische und kulturelle Barrieren, die laut Schwaeke et al. (2024) bislang wissenschaftlich vernachlässigt wurden. Ferner steht der Mittelstand vor der Herausforderung, den langfristigen Nutzen der KI-Implementierungen zu bewerten und zu quantifizieren. Das Fehlen klarer Erfolgskriterien und Bewertungsmaßstäbe erschwert strategische Entscheidungen und führt zu Unsicherheiten bei Investitionsentscheidungen (Mesloh, 2021; Oldemeyer et al., 2024). Zusätzlich verstärken die Integration neuer KI-Anwendungen in bestehende Systemlandschaften und die Notwendigkeit umfassender Mitarbeiterschulungen diese Problematik (Schönberger, 2023; Schwaeke et al., 2024).

Ein weiterer kritischer Aspekt ist die skeptische Haltung gegenüber der Einführung generativer KI. Besonders mittelständische Unternehmen befürchten, dass die Technologie zu komplex oder kostenintensiv ist, und verfügen zudem nicht über das notwendige Wissen, um Implementierungsprojekte erfolgreich zu managen (Enshassi et al., 2024; Kanbach et al., 2023). Diese Vorbehalte werden durch unklare Erwartungen bezüglich des Return on Investment (ROI) und die Unsicherheit über die langfristige Verfügbarkeit und Weiterentwicklung der Technologie verstärkt (L. Chen et al., 2022). Schließlich stellt der Widerstand der Mitarbeiter*innen ein zentrales Implementierungshemmnis dar. Häufig führen Implementierungsvorhaben zu Befürchtungen bezüglich Arbeitsplatzverlust, Kompetenzzentwertung

und veränderten Arbeitsabläufen (Bettoni et al., 2021; Schwaeke et al., 2024). Das mangelnde Vertrauen in die Technologie und die Schwierigkeiten der Akzeptanz gegenüber organisatorischen Transformationsprozessen behindern die Implementierungsversuche im Mittelstand erheblich (Rajaram & Tinguely, 2024).

Vor dem Hintergrund der zuvor beschriebenen Forschungsprobleme lassen sich schließlich fünf wesentliche Forschungslücken im Kontext des deutschen Mittelstands identifizieren:

- (1) Es fehlt an systematischen Untersuchungen zum Implementierungsprozess generativer KI in mittelständischen Unternehmen, welche die Phasen, Meilensteine und Akteurskonstellationen abbilden.
- (2) Es mangelt an Analysen zu den strategischen Ansätzen und Entscheidungsrahmen, mit denen der Mittelstand seine Implementierungsvorhaben plant und steuert.
- (3) Es fehlt an Forschung zu den konkreten Basistechnologien – etwa Modellarchitekturen, Datenpipelines und Integrationsschnittstellen –, die für die Implementierung in der Praxis kaum vorhanden ist.
- (4) Es fehlen Fallstudien, die sowohl gelungene als auch gescheiterte Einführungsprojekte aus dem deutschen Mittelstand dokumentieren und daraus Erfolgs- und Risikofaktoren ableiten.
- (5) Es bestehen unzureichende Erkenntnisse darüber, welche Auswirkungen und Bewertungskriterien sich speziell für Fachbereiche wie das Marketing ergeben, wenn generative KI in Arbeitsabläufe integriert wird.

Die skizzierten Forschungsprobleme und -lücken verdeutlichen, dass trotz des erheblichen Potenzials für den deutschen Mittelstand wesentliche Wissenslücken bezüglich der praktischen Implementierung und organisatorischen Gestaltung bestehen. Um diesen Defiziten gezielt und systematisch zu begegnen, werden im nachfolgenden Kapitel die forschungsleitende Fragestellung sowie die konkreten Zielsetzungen dieser Forschungsarbeit abgeleitet. Dieser Schritt überführt die Problembeschreibung in einen strukturierten Untersuchungsrahmen.

1.2 Forschungsleitende Fragestellung und Zielsetzungen

Auf Basis der zuvor erläuterten Forschungsprobleme und -lücken wird das methodische Gerüst dieser Forschungsarbeit nun präzisiert. Eine präzise formulierte Leitfrage bildet den Bezugsrahmen für alle weiteren Untersuchungsschritte, während ergänzende Fragestellungen verschiedene Facetten des Forschungsgegenstands vertiefen. Auf dieser Grundlage werden

sowohl ein primäres als auch mehrere sekundäre Forschungsziele definiert. Die leitende Forschungsfrage (LF) fasst die in Kapitel 1.1 beschriebenen Unsicherheiten in Bezug auf die Prozessgestaltung, strategische Planung und Technologieauswahl übergreifend zusammen und lautet:

(LF): Wie kann sich der Implementierungsprozess generativer KI für deutsche KMU ausgestalten, und welche strategischen Ansätze sowie zugrunde liegenden Basistechnologien können hierbei Anwendung finden?

Mit dieser Frage wird untersucht, wie Unternehmen von der Initiierung bis hin zur praktischen Integration und Steuerung ihrer KI-Projekte vorgehen können. Zur vertiefenden Untersuchung des Implementierungsprozesses werden fünf ergänzende Forschungsfragen (EF) vorgestellt. Sie ermöglichen eine gezielte Betrachtung der einzelnen Bausteine – von der Planung über die technische Realisierung bis zur Erfolgskontrolle und Roadmap-Entwicklung. In Tabelle 1 sind diese den jeweiligen Forschungsproblemen und -lücken zugeordnet und mit einem Forschungsziel verknüpft.

Tabelle 1: Ableitung Forschungsfragen und Zielsetzungen

Forschungsprobleme (Kapitel 1.1)	Forschungslücken (Kapitel 1.1)	Ergänzende Forschungsfragen	Forschungsziel (primär, sekundär)
Unklare Prozessgestaltung bei KI-Einführung	Systematische Prozessanalyse im Mittelstand fehlt	EF1: Wie können deutsche KMU bei der Implementierung von generativer KI vorgehen, und welche Schritte charakterisieren diesen Prozess?	Primärziel: Entwicklung eines Implementierungsframeworks, das die prozessorientierte Einführung generativer KI skizziert.
Unzureichende strategische Planungsansätze	Strategische Ansätze sind wenig erforscht	EF2: Welche strategischen Ansätze können deutsche KMU zur Implementierung von generativer KI verfolgen?	Sekundärziel 1: Analyse und Ableitung strategischer Planungsansätze.
Mangelndes Wissen über eingesetzte Basistechnologien	Details zu Basistechnologien sind kaum dokumentiert	EF3: Welche Basistechnologien können von deutschen KMU zur Implementierung von generativer KI herangezogen werden?	Sekundärziel 2: Identifikation und Beschreibung der in der Praxis eingesetzten Basistechnologien.
Fehlende Evaluation des Implementierungserfolgs	Bewertungskriterien und Erfolgsindikatoren fehlen	EF4: Welche Bewertungskriterien können deutsche KMU anwenden, um den Erfolg der Implementierung zu beurteilen?	Sekundärziel 3: Ableitung und Beschreibung von Kriterien und Messgrößen zur Evaluation des Implementierungserfolgs.
Mangelnde Ableitung künftiger Implementierungsschritte	Roadmap-Entwicklung ist unzureichend erforscht	EF5: Wie können deutsche KMU ihre KI-Roadmap formulieren und welche fortführenden Implementierungsmaßnahmen können sie hieraus ableiten?	Sekundärziel 4: Entwicklung fundierter Empfehlungen zur Formulierung und Weiterentwicklung einer KI-Roadmap.

Quelle: Eigene Darstellung

Die konsolidierte Darstellung veranschaulicht, dass jede Forschungsfrage direkt aus einer Problemstellung und der zugehörigen Forschungslücke abgeleitet wurde und einer Zielsetzung zugeordnet ist. Im Zentrum dieser Forschungsarbeit steht somit die Erarbeitung eines Frameworks für den Implementierungsprozess generativer KI in mittelständischen Unternehmen. Darauf aufbauend gliedern sich die Sekundärziele wie folgt auf: Zunächst wird die strategische Ebene adressiert, indem die Planung und Steuerung von KI-Anwendungen analysiert wird. Anschließend erfolgt die technische Dimension, in der die Auswahl und Integration von Basistechnologien systematisch untersucht wird. Daraufhin folgt die Evaluationsperspektive, die Kriterien und Indikatoren zur Bewertung des Implementierungserfolgs herausarbeitet. Abschließend werden handlungsorientierte Empfehlungen für die Formulierung und iterative Weiterentwicklung einer KI-Roadmap abgeleitet.

Aufbauend auf den in diesem Kapitel definierten Forschungsfragen und Zielen skizziert das folgende Kapitel 1.3 den strukturellen Aufbau der Forschungsarbeit. Es wird dargelegt, wie die einzelnen Kapitel logisch aufeinander aufbauen, um die Forschungsfragen systematisch zu beantworten und die gesetzten Ziele zu erreichen. Dabei wird auch die methodische Vorgehensweise zur Überprüfung der Ergebnisse vorgestellt.

1.3 Struktureller Aufbau

Die Grundlage dieser Forschungsarbeit bildet die in Kapitel 2 durchgeführte systematische Literaturrecherche, die sich an der PRISMA-Methodik orientiert und den aktuellen Forschungsstand zur Implementierung von KI-Anwendungen in Unternehmen aufarbeitet. In Kapitel 2.1 werden Suchstrategie, Datenbankauswahl sowie Ein- und Ausschlusskriterien beschrieben. Die darauffolgenden Unterkapitel 2.2 bis 2.5 widmen sich der Analyse zentraler Themenbereiche wie Prozessmodelle, strategische Planungsansätze, Basistechnologien und Evaluationskriterien und liefern so die theoretische Basis für die geplante Untersuchung.

Während Kapitel 2 den breiten Stand der Forschung abbildet, widmet sich Kapitel 3 der gezielten Schaffung des theoretischen Fundaments für die vorliegende Forschungsarbeit. Das Vorgehen gliedert sich in zwei logische Schritte: Zunächst werden relevante Theorien identifiziert und selektiert (Kapitel 3.2), bevor diese anschließend anhand definierter Kriterien bewertet und zudem in Kategorien eingeteilt werden (Kapitel 3.3). Ziel ist die Herleitung einer tragfähigen und begründeten theoretischen Grundlage für die spätere Framework-Entwicklung.

Das methodische Fundament der Untersuchung legt Kapitel 4 dar. Es stellt zunächst das qualitative Forschungsdesign und dessen systematischen Aufbau vor (Kapitel 4.1). Den Kern der Methodik bildet ein dreiphasiger Forschungsprozess, der die systematische Entwicklung des Frameworks sicherstellt: Phase 1 umfasst die Datenerhebung mittels halbstrukturierter Interviews und begleitender Dokumentenanalyse (Kapitel 4.2). Auf dieser Basis wird in Phase 2 ein erster Framework-Entwurf konstruiert (Kapitel 4.3), der schließlich in Phase 3 durch Folgegespräche mit den Expert*innen validiert und finalisiert wird (Kapitel 4.4). Den Abschluss des Methodenkapitels bildet eine Retrospektive auf Basis von zuvor festgelegten Gütekriterien und Praxisanforderungen (Kapitel 4.5).

Aufbauend auf dem in Kapitel 4 dargelegten Vorgehen, präsentiert Kapitel 5 die Ergebnisse und folgt dabei konsequent der dreiphasigen Logik der Methodik. Zunächst werden in Kapitel 5.2 die zentralen Erkenntnisse aus den Expert*inneninterviews und der Dokumentenanalyse (Phase 1) zusammengefasst. Auf dieser Basis wird in 5.3 der daraus abgeleitete Erstentwurf des Implementierungsframeworks (Phase 2) vorgestellt. Die darauffolgenden Kapitel 5.4 und 5.5 widmen sich den Ergebnissen der Validierungsphase (Phase 3), indem sie die Resultate der Folgegespräche sowie die finalen Anpassungen am Framework darlegen.

Die abschließende Diskussion in Kapitel 6 führt die Ergebnisse zusammen und ordnet sie in den wissenschaftlichen sowie praktischen Kontext ein. Kapitel 6.1 präsentiert zunächst die Kernergebnisse der Forschungsarbeit und beantwortet die leitenden Forschungsfragen. Darauf aufbauend wird in Kapitel 6.2 der wissenschaftliche Beitrag der Untersuchung herausgearbeitet. Kapitel 6.3 formuliert konkrete, praxisorientierte Handlungsempfehlungen für Unternehmen. Anschließend reflektiert Kapitel 6.4 kritisch die methodische Güte der Forschungsarbeit. Den Abschluss bildet Kapitel 6.5 mit einer Zusammenfassung und einem Forschungsausblick, der Potenziale für weiterführende Studien aufzeigt.

Die Tabelle 2 bietet einen Überblick über den strukturellen Aufbau der Forschungsarbeit. Sie veranschaulicht, wie die in Kapitel 1.1 identifizierten Forschungsprobleme und -lücken systematisch in den einzelnen Kapiteln adressiert werden. Konkret ordnet sie jedem Kapitel die jeweiligen Forschungsfragen, die zur Anwendung kommenden Methoden und den Beitrag zur Erreichung der Forschungsziele zu.

Tabelle 2: Überblick zum strukturellen Aufbau der Forschungsarbeit

Kapitel	Inhaltlicher Schwerpunkt	Ergänzende Forschungsfragen	Methodik	Zielsetzung und Erkenntnisziele
2	Systematische Literaturrecherche (PRISMA) und Stand der Forschung	1 bis 4	PRISMA-Flowchart, Datenbankrecherche	Identifikation des aktuellen Forschungsstands zu Prozessmodellen, Strategie, Basistechnologien und Evaluation
3	Theoretische Verankerung: Identifizierung und Bewertung relevanter Theorien	–	Systematische Theoriebewertung	Schaffung einer fundierten theoretischen Basis für das Implementierungsframework
4	Methode: Forschungsdesign, Sampling und dreiphasiges Vorgehen	5	Halbstrukturierte Expert*inneninterviews, Dokumentenanalyse	Operationalisierung der empirischen Untersuchung; Entwurf und Validierung des Implementierungsframeworks
5	Empirische Ergebnisse: Datenaufbereitung, Entwurf, Validierung und Weiterentwicklung	1 bis 5	Qualitative Inhaltsanalyse, Framework Analysis	Beantwortung der Forschungsfragen; Entwicklung und Finalisierung des Implementierungsframeworks
6	Diskussion: wissenschaftlicher Beitrag, Handlungsempfehlungen, Zusammenfassung und Forschungsausblick	1 bis 5	Synthese, Reflexion	Integration der Ergebnisse; Formulierung wissenschaftlicher Beiträge und praxisrelevanter Empfehlungen; Forschungsimpulse

Quelle: Eigene Darstellung

Die Kapitel 2 bis 6 sind so konzipiert, dass sie eine stringente, aufeinander aufbauende Analyse von Theorie, Methodik und Empirie gewährleisten. Kapitel 2 legt durch die Aufarbeitung des Forschungsstandes das Fundament. Darauf errichtet Kapitel 3 die theoretische und Kapitel 4 die methodische Basis der Untersuchung. Kapitel 5 präsentiert die daraus gewonnenen empirischen Ergebnisse, welche abschließend in Kapitel 6 umfassend diskutiert, in ihren Implikationen bewertet und in einen Forschungsausblick überführt werden. Entsprechend der dargelegten Gliederung beginnt die inhaltliche Auseinandersetzung im folgenden Kapitel mit der systematischen Aufarbeitung des aktuellen Forschungsstandes.

2 STAND DER AKTUELLEN FORSCHUNG

2.1 Systematik der Literaturrecherche in Anlehnung an PRISMA-Methodik

2.1.1 Zielsetzung und methodische Orientierung

Dieses Kapitel legt das methodische Vorgehen der systematischen Literaturrecherche dar, um die Reproduzierbarkeit der Ergebnisse zu gewährleisten. Im Mittelpunkt steht somit die Darlegung der einzelnen Schritte der Literatursuche und -auswertung. Dazu gehören die Abgrenzung des Forschungsfeldes, die Entwicklung und Umsetzung der Suchstrategie, die Definition und Begründung der Ein- und Ausschlusskriterien sowie dessen Anwendung und Ergebnisdarstellung.

Hervorzuheben ist, dass die PRISMA-Methodik als strukturgebender Leitfaden für die Dokumentation des Literatursuchprozesses fungiert (Page, Moher, et al., 2021). Aufgrund der methodischen und thematischen Vielfalt der wirtschafts- und sozialwissenschaftlichen Literatur zum Forschungsgegenstand wird die Methodik nicht im vollen Umfang, sondern in adaptierter Form angewendet (Boaye Belle & Zhao, 2023; Nezameslami et al., 2025). Insbesondere die Einbeziehung verschiedener Publikationstypen und Forschungsdesigns erfordert eine flexible Umsetzung der PRISMA-Vorgaben (Page, McKenzie, et al., 2021). Somit sind zentrale Prinzipien wie die strukturierte Erfassung, das Screening und die transparente Auswahl übernommen worden (Nezameslami et al., 2025). Andere Elemente, wie etwa die detaillierte Dokumentation einer jeden Phase mittels Protokoll sowie die Bewertung der Studienqualität mittels Codierschemata, sind ausgelassen oder in reduzierter Form angewendet worden (Boaye Belle & Zhao, 2023). Die Vorgehensweise wird daher als „in Anlehnung an die PRISMA-Methodik“ beschrieben.

2.1.2 Abgrenzung des Forschungsfeldes

Die Recherche konzentriert sich auf drei Themenbereiche. Der erste rückt den Mittelstand – konkret KMU im deutschen und internationalen Kontext – in den Fokus, da diese Unternehmensstruktur in besonderer Weise von den Herausforderungen und Chancen der digitalen Transformation betroffen ist (Mesloh, 2021; Rajaram & Tinguely, 2024). Im Unterschied zu Großunternehmen verfügen sie häufig über begrenzte personelle, finanzielle und technologische Ressourcen, wodurch die Einführung und nachhaltige Nutzung innovativer Technologien wie generativer KI maßgeblich beeinflusst wird (Oldemeyer et al., 2024; Schwaeke et al., 2024). Gleichzeitig sind KMU in Europa und insbesondere in Deutschland strukturell

und wirtschaftlich von zentraler Bedeutung, da sie einen Großteil der Wertschöpfung, Beschäftigung und Innovationsleistung tragen (Mesloh, 2021). Demzufolge hat die wissenschaftliche Auseinandersetzung mit der Implementierung dieser Technologie sowohl theoretische als auch praktische Relevanz, die sich unmittelbar aus ihrer Bedeutung für den Mittelstand ableitet.

Der zweite, technisch geprägte Themenbereich widmet sich der generativen KI, die einen qualitativen Sprung in der Entwicklung und Anwendung von KI markiert (Feuerriegel et al., 2023). Während klassische KI-Anwendungen vor allem auf die Automatisierung von Routineaufgaben und die Analyse umfangreicher Datenmengen abzielen, ermöglicht generative KI die eigenständige Erzeugung neuartiger Inhalte und Geschäftsmodelle (Glauner, 2024). Insbesondere für KMU eröffnen sich neue Potenziale zur Effizienzsteigerung, Individualisierung von Produkten und Dienstleistungen sowie zur Entwicklung innovativer Geschäftsprozesse (Oldemeyer et al., 2024). Gleichzeitig stellen sich spezifische Herausforderungen hinsichtlich Integration, Akzeptanz, Governance und ethischer Verantwortung, die bislang in der Forschung unzureichend adressiert wurden (D. Kumar & Ratten, 2024).

Der dritte und letzte Themenbereich widmet sich der geografischen Eingrenzung auf Deutschland und Europa. Diese Fokussierung begründet sich dadurch, dass der regulatorische, wirtschaftliche und kulturelle Kontext die Rahmenbedingungen für die Einführung generativer KI maßgeblich bestimmt (Gualandri & Kuzior, 2024; Peres et al., 2020). Mittelständische Unternehmen in der EU stehen vor spezifischen Herausforderungen im Bereich Datenschutz, IT-Sicherheit und ethischen Standards, die sich von den Bedingungen in anderen Weltregionen unterscheiden (Mesloh, 2021). Die Berücksichtigung dieser regionalen Besonderheiten ist erforderlich, um die Forschungsergebnisse valide und praxisnah auf die Zielgruppe anwenden zu können.

2.1.3 Suchstrategie und Datenbankauswahl

Die Identifikation relevanter Studien erfolgt durch eine systematische Recherche in führenden wissenschaftlichen Datenbanken, darunter Emerald Insight, Science Direct, Springer-Link, IEEE Xplore, Wiley Online Library, Taylor & Francis Online sowie Google Scholar. Diese wurden gezielt ausgewählt, da sie eine hohe Relevanz für die zuvor erläuterten Themenbereiche aufweisen und Journale von internationaler Sichtbarkeit sowie wissenschaftlicher Anerkennung darstellen. Geleitet von den in Kapitel 1 formulierten Forschungsfragen, zielt die Suchstrategie darauf ab, die technologischen, organisatorischen und strategischen

Dimensionen des Forschungsgegenstandes systematisch zu erfassen. Die notwendige thematische Breite und Tiefe wird durch den Einsatz unterschiedlicher Schlagwortkombinationen gewährleistet, die aus Tabelle 3 entnommen werden können.

Tabelle 3: Verwendete Schlagwortkombination innerhalb der Literatursuche

Themenfeld	Schlagwortkombinationen
Generative KI allgemein	generative artificial intelligence, generative AI, large language models, diffusion models
Unternehmenskontext	small and medium enterprises, SMEs, Mittelstand, business, implementation, adoption
Implementierungsprozess	implementation process models, phases, roadmaps, strategic planning, evaluation criteria
Governance & Strategie	governance, leadership, change management, organizational learning, regulatory compliance
Geografischer Fokus	Germany, Europe, European Union, EU, Deutschland

Quelle: Eigene Darstellung

Die dargestellten Suchanfragen werden jeweils mit Operatoren (AND, OR) kombiniert, um sowohl spezifische als auch breit gefasste Ergebnisse zu erzielen. Anschließend erfolgt die Auswahl und Kombination der Suchbegriffe fortlaufend und wird regelmäßig überprüft sowie bei Bedarf erweitert, um sicherzustellen, dass aktuelle technologische Entwicklungen ebenso wie organisationale und strategische Fragestellungen angemessen berücksichtigt werden.

2.1.4 Auswahl und Begründung von Ein- und Ausschlusskriterien

Die Auswahl der Studien für die vorliegende Literaturanalyse erfolgt anhand klar definierter Ein- und Ausschlusskriterien, die in Tabelle 4 zusammengefasst sind. Diese Kriterien wurden entwickelt, um eine hohe Relevanz, Qualität und Vergleichbarkeit der eingeschlossenen Arbeiten sicherzustellen.

Tabelle 4: Ein- und Ausschlusskriterien der Literaturanalyse

Kriterium	Einschluss (Inklusion)	Ausschluss (Exklusion)
Publikationstyp	Peer-Reviewed Artikel, Konferenzbeiträge, Reviews, konzeptionelle Arbeiten	Nicht-wissenschaftliche Quellen, graue Literatur
Zeitraum	Veröffentlichungen von 2020 bis 2025	Publikationen vor 2020
Sprache	Englisch und Deutsch	Sprachen außerhalb von Englisch und Deutsch
Thematischer Bezug	Generative KI, Implementierung, Evaluation, Roadmaps, Governance in KMU	Kein klarer Bezug zu KMU oder generativer KI
Geografischer Fokus	Deutschland und Europa	Regionen außerhalb Europa
Methodik	Empirische Studien bevorzugt, aber auch Reviews und konzeptionelle Arbeiten einbezogen	Nicht-empirische, nicht-theoretische Beiträge

Quelle: Eigene Darstellung

Die gezielte Auswahl von peer-reviewed Publikationen und Konferenzbeiträgen gewährleistet, dass ausschließlich wissenschaftlich geprüfte und qualitativ hochwertige Arbeiten in die Analyse einbezogen werden. Zudem wird ein Untersuchungszeitraum von 2020 bis 2025 gewählt, um die Aktualität der Forschungsergebnisse sicherzustellen, da der Forschungsgegenstand einem besonders dynamischen Wandel unterliegt. Es werden primär Studien in deutscher und englischer Sprache berücksichtigt, da diese im wissenschaftlichen Diskurs des Forschungsfeldes dominieren und eine zuverlässige inhaltliche Erschließung gewährleisten. Ferner werden ausschließlich Studien einbezogen, deren Forschungsschwerpunkt auf Deutschland oder anderen europäischen Ländern liegt, um den spezifischen regulatorischen, wirtschaftlichen und kulturellen Kontexten Rechnung zu tragen. Letztlich wird der thematische Bezug zu generativer KI und KMU als Kriterium festgelegt, um die Forschungsfragen zielgerichtet zu adressieren und die Übertragbarkeit der Ergebnisse sicherzustellen.

2.1.5 Anwendung und Ergebnisse der systematischen Literaturrecherche

Die in Kapitel 2.1.2 abgegrenzten Forschungsfelder fungieren als Grundlage zur Anwendung innerhalb der Literaturrecherche und bilden entsprechende Themenbereiche. Zunächst werden alle Treffer aus den Datenbanken gesammelt und Duplikate entfernt. Anschließend erfolgt das Screening der Titel und Abstrakte anhand der definierten Ein- und Ausschlusskriterien. In einem weiteren Schritt werden die Volltexte der verbleibenden Publikationen geprüft und abschließend diejenigen Studien eingeschlossen, die den Anforderungen entsprechen. Eine Übersicht zur Quantität ausgewählter Studien ist Abbildung 1 zu entnehmen.

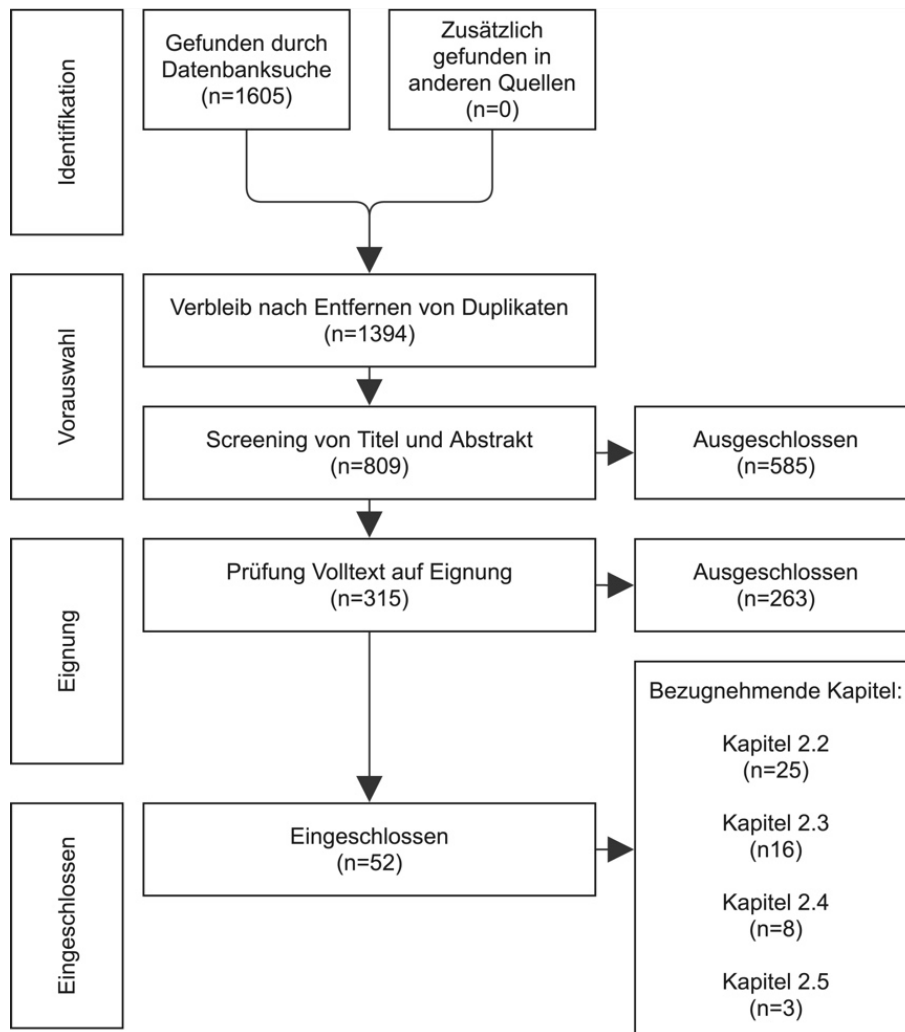


Abbildung 1: PRISMA-Flowchart ein- und ausgeschlossener Studien

Quelle: Eigene Darstellung in Anlehnung an Page et al. (2021)

Das Flowchart verdeutlicht die Breite und Tiefe der systematischen Literaturrecherche. Es wird deutlich, dass je nach Themenbereich die Anzahl der eingeschlossenen Studien variiert. Dies spiegelt sowohl die Heterogenität als auch die unterschiedliche Forschungsdichte wider. Während die Kapitel 2.2 (25 Studien) und 2.3 (16 Studien) eine hohe Forschungsdichte aufweisen, steht den Kapiteln 2.4 sowie 2.5 mit 11 Studien eine zwar geringere, aber inhaltlich fokussiertere Studienlage gegenüber. Mit dieser Verteilung wird die Notwendigkeit unterstrichen, die jeweiligen Erkenntnisse differenziert und kontextbezogen zu betrachten. Somit folgt in den nächsten Kapiteln eine vertiefende Darstellung der wesentlichen Rechercheergebnisse, die auf der Grundlage der zuvor vorgestellten Themenbereiche differenziert werden.

2.2 Generative KI: Begriffsbestimmung und technologische Grundlagen

2.2.1 Begriffliche Einordnung und Definition generativer KI

Im Gesamtfeld der KI stellt generative KI ein Teilgebiet des maschinellen Lernens (ML) dar, das wiederum eine der beiden zentralen Entwicklungslinien der KI neben den klassischen Expertensystemen bildet (Glauner, 2024). Während ML darauf abzielt, Muster und Zusammenhänge in Daten zu erkennen und daraus Vorhersagen oder Entscheidungen abzuleiten, fokussiert sich generative KI speziell auf die Fähigkeit, neuartige, plausible Datenpunkte zu erzeugen (Liu et al., 2011; Ren et al., 2025; C. Zhao et al., 2024). Technisch basiert ein Großteil auf tiefen neuronalen Netzwerken (Deep Learning), die als Teilbereich des ML zu verstehen sind. Diese Netzwerke, insbesondere in Form von Transformer-Architekturen, ermöglichen es, komplexe Wahrscheinlichkeitsverteilungen zu modellieren und dadurch eigenständig neuartige Inhalte zu generieren (Feuerriegel et al., 2023). Im Unterschied zu klassischen, überwiegend diskriminativen KI-Ansätzen – die vor allem für Klassifikations- oder Vorhersageaufgaben eingesetzt werden und Muster in bestehenden Daten erkennen – steht bei generativer KI die Synthese differenzierter Datenformate im Vordergrund. Sie bezeichnet eine Klasse von Algorithmen, die darauf ausgelegt sind, eigenständig Inhalte zu erzeugen, indem sie die zugrundeliegenden Wahrscheinlichkeitsverteilungen von Trainingsdaten modellieren (Feuerriegel et al., 2023; Glauner, 2024; Xu et al., 2024). Somit ist die Abgrenzung zwischen generativer und diskriminativer KI von zentraler Bedeutung, da sie die Grundlage für die Bewertung von Einsatzmöglichkeiten, Potenzialen und Herausforderungen im Unternehmenskontext bildet. Insbesondere im Mittelstand eröffnet generative KI neue Möglichkeiten zur Automatisierung von Prozessen, zur Entwicklung neuer Produkte und zur Individualisierung von Dienstleistungen, während diskriminative Ansätze vor allem für analytische und klassifizierende Aufgaben eingesetzt werden (Schönberger, 2023; Schwaewe et al., 2024).

In der Literatur wird generative KI häufig als eine Klasse von Algorithmen beschrieben, die nicht ausschließlich bestehende Informationen verarbeiten, sondern aktiv neuartige Inhalte schaffen können. Diese Fähigkeit zur Synthese basiert auf probabilistischen Modellen, welche die inhärente Struktur und die Zusammenhänge innerhalb der Daten erfassen und daraus originäre, aber konsistente Ergebnisse generieren (Liu et al., 2011; Ren et al., 2025; C. Zhao et al., 2024). Im Gegensatz zu diskriminativen Ansätzen, die eine Trennlinie zwischen ver-

schiedenen Klassen ziehen, modellieren Verfahren der generativen KI die gesamte Datenverteilung und sind dadurch in der Lage, Daten zu erzeugen, die den Eigenschaften der Trainingsdaten entsprechen. Dabei sind typische Anwendungsfelder die automatisierte Textgenerierung, die Erzeugung von Bildern, Videos und Grafiken, die Erstellung von Audiosequenzen und Musik sowie die Erzeugung von Programmcode. Darüber hinaus werden entsprechende Modelle zunehmend für die Synthese von multimodalen Inhalten eingesetzt, bei denen verschiedene Datenformate wie Text, Bild und Audio gleichzeitig verarbeitet und generiert werden können (Chern et al., 2024; Pan et al., 2024). Maßgeblich für die jüngsten Fortschritte in der generativen KI sind die Etablierung von Transformer-Architekturen, die auf Attention-Mechanismen¹ basieren und die bis dahin führenden rekurrenten sowie konvolutionalen Modelle² ablösen (Glauner, 2024; Vaswani et al., 2023). Diese Entwicklung hat die Leistungsfähigkeit der Technologie gesteigert und die Grundlage für moderne Large Language Models (LLM) und multimodale Systeme geschaffen.

Die zuvor dargestellte begriffliche Abgrenzung und die Charakterisierung generativer KI verdeutlichen, dass die Fähigkeit zur eigenständigen Inhaltserzeugung maßgeblich auf spezifischen algorithmischen und architektonischen Prinzipien beruht. Um ihre Funktionsweise zu verstehen, ist es erforderlich, die zugrundeliegenden technologischen Grundlagen zu betrachten. Dementsprechend gewährt das folgende Kapitel einen vertiefenden Einblick in relevante Modelltypen, Architekturen und Trainingsmethoden.

2.2.2 Technologische Grundlagen generativer KI

Die Entwicklung der Technologie basiert auf einer Vielzahl spezialisierter Modelltypen, die sich hinsichtlich ihrer architektonischen Prinzipien und Trainingsmethoden unterscheiden (Glauner, 2024). Im Zentrum stehen moderne Deep-Learning-Ansätze, insbesondere Transformer-Architekturen, die die Generierung und Verarbeitung komplexer Datenformate ermöglichen. Je nach Anwendungsfeld werden unterschiedliche Modelle verwendet, deren Auswahl wesentlich die Leistungsfähigkeit und Anwendungsbreite generativer KI bestimmt. Im Folgenden werden die zentralen Modelltypen und ihre jeweiligen Funktionsprinzipien systematisch dargestellt.

Gegenwärtig bilden Transformatoren-basierte LLMs das Rückgrat generativer KI-Anwendungen, insbesondere im Bereich der Sprachverarbeitung und bei multimodalen Aufgaben. Sie

¹ Siehe Anhang M für ausführliche Erläuterungen.

² Ebd.

basieren auf Transformer-Architekturen, die ausschließlich Attention-Mechanismen nutzen und damit auf rekurrente oder konvolutionale Strukturen verzichten (Vaswani et al., 2023; Xue et al., 2024). LLMs werden auf umfangreichen Textkorpora trainiert und sind in der Lage, Sprache zu verstehen und kontextbezogen zu generieren. Sie verfügen über multimodale Fähigkeiten und können beispielsweise Bild- und Textinformationen gemeinsam verarbeiten (Chern et al., 2024; Pan et al., 2024). Charakteristisch sind zudem Few-Shot-Learning³ und die flexible Anpassung an neue Aufgaben durch In-Context-Learning⁴ (Chern et al., 2024; Xue et al., 2024).

Diffusionsmodelle stellen einen weiteren Ansatz zur Erzeugung hochqualitativer Bilder und anderer Medien dar. Sie dienen häufig als technologische Grundlage für die generative Bildsynthese. Diese Modelle basieren darauf, Daten schrittweise in Rauschen zu transformieren und diesen Prozess anschließend umzukehren, um neue, realistische Datenpunkte zu erzeugen. Im Trainingsprozess wird ein Eingabedatensatz – beispielsweise ein Bild – über viele Iterationen hinweg sukzessive verrauscht, bis nur noch reines Rauschen übrig bleibt (Z. Li et al., 2024). Das Modell lernt dann, diesen Rauschprozess in kleinen Schritten umzukehren, sodass aus dem Rauschen wieder ein plausibles Bild rekonstruiert werden kann. Durch diese iterative Denoising-Prozedur⁵ sind Diffusionsmodelle in der Lage, hochauflösende und detailreiche Inhalte zu generieren. Sie werden insbesondere für die Bildsynthese eingesetzt, finden aber zunehmend auch Anwendung in anderen Bereichen wie der Text-zu-Bild-Generierung und der Audioerzeugung (Z. Li et al., 2024; Luo et al., 2024).

Einen nächsten zentralen Ansatz repräsentieren Generative Adversarial Networks (GAN), die realistisch wirkenden Datenoutput erzeugen können, vor allem im Bildbereich. Sie nutzen ein adversariales Trainingsverfahren, bei dem ein Generator und ein Diskriminator in einem Wettbewerb zueinander stehen: Der Generator erzeugt neue Datenpunkte, während der Diskriminator versucht, zwischen echten und vom Generator erzeugten (manipulierten) Daten zu unterscheiden (Goodfellow et al., 2020). Ziel ist es, dass der Generator im Verlauf des Trainings immer realitätsnähere Datenbeispiele produziert. GAN finden vor allem bei der Bildgenerierung und der Datenaugmentation⁶ Anwendung (Glauner, 2024; Z. Li et al., 2024).

³ Siehe Anhang M für ausführliche Erläuterungen.

⁴ Ebd.

⁵ Ebd.

⁶ Ebd.

Zu den zentralen Modellen für Datenkompression⁷, Feature Learning⁸ und die Generierung neuer Inhalte zählen Autoencoder sowie Variational Autoencoders (VAE). Während klassische Autoencoder darauf ausgelegt sind, Eingabedaten in eine komprimierte, latente Repräsentation zu überführen und daraus möglichst verlustfrei zu rekonstruieren, erweitern VAE dieses Prinzip um probabilistische Komponenten (Pan et al., 2024). Dadurch sind sie in der Lage, nicht nur effiziente Datenrepräsentationen zu lernen, sondern auch vielfältige und plausible neue Datenpunkte zu erzeugen. Insbesondere im Kontext generativer KI ermöglichen VAE die kontrollierte Erzeugung neuer Inhalte und finden breite Anwendung in Bereichen wie Bild-, Text- und Audioverarbeitung (Feuerriegel et al., 2023; Glauner, 2024).

Zu den zukunftsweisenden Ansätzen im Bereich generativer KI zählen multimodale Systeme, die verschiedene Modelltypen und Datenmodalitäten miteinander kombinieren. Durch die Integration unterschiedlicher Technologien wird die simultane Verarbeitung und Erzeugung von Inhalten über mehrere Medien – etwa Text, Bild, Audio und Video – ermöglicht (Chern et al., 2024; Ren et al., 2025). Besonders Transformer-basierte Modelle wie Vision Transformer, MuseNet oder Video Transformer Network demonstrieren die Flexibilität dieser Architektur und eröffnen neue Anwendungsmöglichkeiten für die KI-gestützte Generierung komplexer, multimodaler Inhalte. Insbesondere die Vielseitigkeit und Skalierbarkeit von Transformer-Modellen hat die Entwicklung von Foundation Models wie GPT-2/3/4/5 und deren multimodalen Erweiterungen ermöglicht, die als Basis für zahlreiche Anwendungen dienen (Glauner, 2024). Aktuelle Entwicklungen verdeutlichen, dass zunehmend hybride Ansätze verfolgt werden, bei denen unterschiedliche Modelltypen miteinander kombiniert werden. Ziel ist es, die jeweiligen Vorteile dieser Technologien zu bündeln und dadurch sowohl die Qualität der generierten Inhalte zu verbessern als auch neue, vielseitige Anwendungsfelder zu erschließen (C. Zhao et al., 2024).

Während dieses Kapitel die technologische Basis legt, widmet sich das nachfolgende Kapitel der Relevanz zur praktischen Anwendung und untersucht, wie diese in KMU integriert werden können.

2.2.3 Relevanz und Integration von KI-Anwendungen in Unternehmen

KI eröffnet Unternehmen vielfältige Einsatzmöglichkeiten, die sich auf zahlreiche Fachbereiche erstrecken. Die aktuelle Forschung zeigt, dass KI-Anwendungen nicht auf einzelne

⁷ Siehe Anhang M für ausführliche Erläuterungen.

⁸ Ebd.

Abteilungen beschränkt sind, sondern bereichsübergreifend zur Steigerung von Effizienz, Innovationskraft und Wettbewerbsfähigkeit beitragen können (Schönberger, 2023; Schwaeke et al., 2024; Szedlak et al., 2021).

Eine systematische Literaturübersicht von Schwaeke et al. (2024) identifiziert zentrale Funktionsbereiche, in denen KI zur Anwendung kommt. Dazu zählen unter anderem Marketing und Vertrieb, Kundenservice, Personalwesen, Finanzen und Controlling, Produktion und Supply Chain sowie IT und Entwicklung. Eine Untersuchung von Schönberger (2023) betont, dass insbesondere Marketing und Vertrieb zu den Fachbereichen zählen, in denen KI-Anwendungen am häufigsten implementiert werden. So nutzen 52 % der befragten Unternehmen Chatbots oder virtuelle Assistenten, 41 % setzen Empfehlungssysteme ein und 31 % verwenden ML für datengetriebene Analysen und Automatisierung. Auch komplementäre Anwendungen wie Predictive Analytics, Computer Vision und Natural Language Processing finden zunehmend Verbreitung – dies jedoch im geringeren Umfang.

Im Marketing geht der Nutzen weit über die reine Automatisierung bei der Erstellung von Werbetexten, Social-Media-Posts oder Produktbeschreibungen hinaus. Vielmehr ermöglichen KI-Anwendungen eine tiefgreifende Individualisierung der Content-Produktion, indem sie den Tonfall der Kommunikation anpasst, Inhalte gezielt kuratiert und so die Kundenbindung nachhaltig stärkt (Haleem, Javaid, Asim Qadri, et al., 2022; V. Kumar et al., 2024; Schönberger, 2023). Ein zentraler Anwendungsfall ist die Hyper-Personalisierung der Kundenansprache, die durch die Analyse umfangreicher Datenmengen aus Quellen wie ERP-Systemen realisiert wird (A. Kumar et al., 2023). Dabei wird die klassische Kundensegmentierung um verhaltensbezogene und psychologische Dimensionen erweitert, was eine präzisere und wirkungsvollere Zielgruppenansprache ermöglicht (Haleem, Javaid, Asim Qadri, et al., 2022; V. Kumar et al., 2024). Ferner fungieren KI-Anwendungen als intelligente Assistenten, die den Vertriebsprozess aktiv unterstützen. So übernehmen Chatbots und virtuelle Agenten nicht nur die Erstkommunikation und Beantwortung häufiger Fragen, sondern sammeln als lernende Systeme auch wertvolle Kundendaten (Haleem, Javaid, Asim Qadri, et al., 2022). Sie qualifizieren Leads durch gezielte Interaktionen vor und leiten diese effizient an den menschlichen Vertrieb weiter. Dieser Ansatz entlastet die Mitarbeitenden von repetitiven Aufgaben und schafft Freiräume, damit sie sich auf komplexe Verhandlungen und den Aufbau von Kundenbeziehungen konzentrieren können (Davenport et al., 2020; V. Kumar et al., 2024).

Mit dem Fortschritt generativer KI gewinnen insbesondere multimodale Systeme zunehmend an Bedeutung. Während klassische KI-Anwendungen häufig auf einzelne Modalitäten beschränkt waren, ermöglichen multimodale Modelle eine ganzheitliche Bearbeitung komplexer Aufgabenstellungen (Chern et al., 2024; Glauner, 2024). Beispielsweise erschließen Foundation Models auf Basis von Transformer-Architekturen durch die gleichzeitige Verarbeitung unterschiedlicher Eingabedaten neue Anwendungsszenarien. Somit erlaubt die Integration multimodaler Systeme, verschiedene Geschäftsprozesse zu bündeln und Synergieeffekte zu nutzen, was insbesondere bei begrenzten personellen und finanziellen Ressourcen relevant ist. Darüber hinaus eröffnet die Kombination von Text-, Bild- und Audiodaten neue Möglichkeiten für datengetriebene Innovationen und die Entwicklung neuer Geschäftsmodelle (Bettoni et al., 2021; Schwaeke et al., 2024).

Die jüngsten Fortschritte generativer KI sind eng mit der Entwicklung leistungsfähiger Foundation Models wie GPT-2/3/4/5 und deren multimodalen Erweiterungen verknüpft, die universell für eine Vielzahl von Anwendungsfeldern dienen (Feuerriegel et al., 2023; Glauner, 2024; Schönberger, 2023). Diese Modelle zeichnen sich durch ihre Vielseitigkeit und Skalierbarkeit aus und ermöglichen es, unterschiedlichste Aufgaben mit hoher Effizienz zu bewältigen. Aktuelle Entwicklungen zeigen zudem einen Trend zu hybriden Architekturen, bei denen verschiedene Modelltypen gezielt kombiniert werden, um die jeweiligen Stärken zu bündeln und sowohl die Qualität der generierten Inhalte als auch die Bandbreite möglicher Einsatzszenarien weiter zu erhöhen (Bengesi, El-Sayed, Sarker, Houkpati, & Oladunni, 2024; C. Zhao et al., 2024).

Aufbauend auf den bisherigen Forschungsstand, widmet sich das folgende Kapitel dem Implementierungsprozess in Unternehmen. Es stellt die Relevanz der Technologie dar, indem es konkrete Anwendungsfälle in betrieblichen Funktionsbereichen aufzeigt und die daraus resultierenden strategischen Implikationen sowie Basistechnologien erörtert.

2.3 Forschungsstand zum Implementierungsprozess von KI-Anwendungen

2.3.1 Prozessmodelle und Phasen der KI-Implementierung

Laut aktueller Studien folgen Implementierungsprozesse typischerweise einem strukturierten Vorgehen, das sich in mehrere abgegrenzte Phasen gliedert (Barcaui & Monat, 2023; Gupta, 2024; Sharma, 2024). Die Abbildung 2 veranschaulicht ein solches Vorgehen, wobei es sich hierbei nicht um ein wissenschaftlich evaluiertes Modell, sondern um eine aus dieser Literaturrecherche abgeleitete Konsolidierung von Kernphasen handelt.




Abbildung 2: Phasen der KI-Implementierung

Quelle: Eigene Darstellung

Zu Beginn steht eine umfassende Bedarfs- und Marktanalyse, um relevante Anwendungsfälle mit hohem Wertschöpfungspotenzial zu identifizieren. Hierbei werden gezielt die Anforderungen der Nutzer*innen erhoben und messbare Key Performance Indicators (KPIs) für die betroffenen Geschäftsprozesse definiert (Sharma, 2024). Die Priorisierung erfolgt unter Berücksichtigung der vorhandenen Ressourcen, Kompetenzen und strategischen Ziele des Unternehmens. In der zweiten Phase werden erste Pilotprojekte oder Proofs-of-Concepts (PoCs) mit begrenztem Umfang durchgeführt, um die technische Machbarkeit und die Akzeptanz der Nutzer*innen zu validieren. Dabei fördert iteratives Experimentieren das organisationsinterne Lernen und ermöglicht eine realistische Einschätzung des Nutzens und der Risiken (Gupta, 2024; Sharma, 2024).

Im Anschluss daran stehen Unternehmen vor der Entscheidung, auf welche Basistechnologie zurückgegriffen werden soll. In dieser Phase ist ein ganzheitlicher Entscheidungsansatz zu berücksichtigen, der Entwicklung, Training, Deployment und Monitoring der gewählten Technologiegrundlage umfasst (Sharma, 2024). In diesem Kontext sind zugleich Investitionsentscheidungen flexibel zu gestalten, um auf Basis erster Ergebnisse das jeweilige Projekt anpassen oder beenden zu können (Barcaui & Monat, 2023). Eine erfolgreiche Implementierung erfordert zudem die Verbindung technischer KI-Kompetenz mit klassischem Projektmanagement. Dazu gehören die Definition von Projektumfang, Risikobewertung, Stakeholder-Analyse, Rollenverteilung sowie die Festlegung von Verantwortlichkeiten für Daten und KI-Ergebnisse (Sharma, 2024). Hierbei ist die menschliche Überprüfung der Ergebnisse essenziell, um Qualität und die Einhaltung von Compliance sicherzustellen (Barcaui & Monat, 2023; Gupta, 2024). In der Integrations- und Deployment-Phase sollten daher KI-Anwendungen in bestehende Arbeitsabläufe integriert, Schnittstellen automatisiert und Systeme zur Leistungs- und Sicherheitsüberwachung etabliert werden. Ein besonderes Augenmerk liegt zugleich auf dem Aspekt Change-Management und der Schulung der Mitarbeitenden, um Akzeptanz und effektive Nutzung zu gewährleisten (Sharma, 2024).

Nach der Einführung ist die kontinuierliche Überwachung und Weiterentwicklung der KI-Anwendung zentral. Dazu zählen Feedbackschleifen, regelmäßige Performance-Analysen und die Dokumentation von Audit-Trails. Die Implementierung wird schließlich als fortlaufender Zyklus verstanden, der Anpassungen und Optimierungen auf Basis von Praxiserfahrungen ermöglicht (Szedlak et al., 2021). Neben diesen operativen Prozessschritten identifiziert die Literatur auch strategische Entscheidungsphasen, die Unternehmen im Zuge der Implementierung durchlaufen. Dazu zählt der bereits beschriebene Aufbau von Wissen und Technologieverständnis, die Durchführung kontrollierter Pilotprojekte, die Entscheidung für das Implementierungsvorhaben mit entsprechender Ressourcenallokation sowie die Institutionalisierung und Skalierung der Technologie in den Geschäftsprozessen. Studien in diesem Bereich betonen, dass der Erfolg dieser Projekte maßgeblich von systematischen Schulungsprogrammen, einer robusten Daten-Governance, iterativen Experimentieransätzen und klaren strategischen Roadmaps abhängt (Gupta, 2024; Huseyn et al., 2024; Sharma, 2024). Zu den größten Herausforderungen zählen dabei begrenzte Ressourcen, technische Komplexität, Widerstände im Change-Management sowie regulatorische Anforderungen (Enshassi et al., 2024; Oldemeyer et al., 2024).

Insgesamt zeigt sich, dass die Implementierung von KI-Anwendungen in Unternehmen nicht ausschließlich einen mehrstufigen Prozess darstellt, sondern technische und organisatorische sowie strategische Aspekte integrieren sollte. Die konsequente Orientierung an den Bedürfnissen der Nutzer*innen, die frühzeitige Einbindung von Stakeholdern und die kontinuierliche Anpassung der Prozesse sind zentral für eine nachhaltige und wertschöpfende Implementierung von KI-Anwendungen. Während die beschriebenen Phasen die operativen und methodischen Grundlagen für die Implementierung liefern, zeigt sich in der Praxis, dass der Erfolg solcher Initiativen ebenso von strategischen, kulturellen und Governance-bezogenen Faktoren abhängt. Das folgende Kapitel beleuchtet daher die Bedeutung strategischer Steuerung, wirksamer Führungsstrukturen und einer adäquaten Governance für die erfolgreiche Einführung und Nutzung von KI-Anwendungen.

2.3.2 Strategische Implikationen und Governance der KI-Implementierung

Die erfolgreiche Einführung von KI-Anwendungen erfordert weit mehr als die bloße Umsetzung der zuvor beschriebenen Phasen. Studien betonen, dass strategische Führung, gezieltes Change-Management, eine innovationsfördernde Unternehmenskultur, kontinuierli-

che Organisationsentwicklung sowie robuste Governance- und Compliance-Strukturen relevante Voraussetzungen für eine nachhaltige und wertschöpfende Implementierung sind (Berger & Von Garrel, 2024; Dey et al., 2024; Oldemeyer et al., 2024; Rajaram & Tinguely, 2024; Sklavos et al., 2024). Im Mittelpunkt steht dabei die Rolle der Unternehmensleitung, dessen Unterstützung und Engagement entscheidende Treiber für den erfolgreichen Einsatz von KI-Anwendungen sind (Berger & Von Garrel, 2024; Rajaram & Tinguely, 2024). Führungskräfte müssen klare Ziele für KI-Anwendungen vorformulieren, diese mit den Geschäftsmodellen und strategischen Prioritäten des Unternehmens verknüpfen und eine schrittweise Skalierung von Pilotprojekten zu unternehmensweiten Anwendungen ermöglichen (Lemos et al., 2022).

Ein weiterer zentraler Aspekt ist der bereits im vorherigen Kapitel beschriebene Aufbau von Kompetenzen und die Förderung organisationalen Lernens. Angesichts häufig begrenzter Ressourcen und des eingeschränkten technischen Know-hows erweist sich die Investition in gezielte Weiterbildungsmaßnahmen und die Entwicklung einer datengetriebenen Denkweise als essenziell (Oldemeyer et al., 2024; Rajaram & Tinguely, 2024). Führungskräfte sind gefordert, eine Kultur zu etablieren, die Experimente und Innovationen zulässt, Fehler als Lernchancen begreift und psychologische Sicherheit für die Mitarbeitenden schafft (Dey et al., 2024). Somit ist die Transformation der Unternehmenskultur hin zu mehr Datenkompetenz und Offenheit für KI ein relevanter strategischer Baustein des Implementierungsprozesses. Insbesondere da Widerstände häufig auf Unsicherheit, mangelndes Verständnis und fehlende Transparenz zurückzuführen sind (Rajaram & Tinguely, 2024; Sklavos et al., 2024). Eine offene Kommunikation, die Einbindung der Mitarbeitenden in Entscheidungsprozesse und die Förderung von AI Literacy sind daher zentrale Elemente einer übergeordneten Change-Management-Strategie.

Governance und ethische Steuerung gewinnen im Kontext zunehmend an Bedeutung. Sklavos et al. (2024) betonen hierbei die Notwendigkeit, KI-bezogene Fragestellungen in die Unternehmensführung und ESG-Agenden zu integrieren. Transparenz, Nachvollziehbarkeit, Datenschutz und Cybersicherheit müssen durch geeignete Richtlinien, Kontrollmechanismen und regelmäßige Audits sichergestellt werden. Insbesondere im europäischen Kontext sind die Einhaltung regulatorischer Vorgaben wie dem EU AI Act sowie die Entwicklung unternehmensspezifischer Ethikrichtlinien von zentraler Bedeutung.

Der Erfolg der Implementierung hängt somit entscheidend von einer ganzheitlichen strategischen Steuerung ab, die technologische, organisatorische und kulturelle Dimensionen vereint. Schließlich muss die Unternehmensleitung als aktiver Treiber auftreten, gezielte Kompetenzentwicklung und kulturellen Wandel fördern sowie Governance- und Compliance-Strukturen etablieren, die sowohl regulatorischen Anforderungen als auch ethischen Standards gerecht werden. Neben strategischer Steuerung, Führung und kulturellem Wandel ist jedoch auch die technologische Basis ein entscheidender Faktor für die Implementierung.

Das folgende Kapitel beleuchtet daher die zentralen Basistechnologien und infrastrukturellen Voraussetzungen, die für einen erfolgreichen und nachhaltigen Einsatz generativer KI in KMU erforderlich sind.

2.3.3 Basistechnologien und technologische Infrastruktur

In Unternehmen weltweit wird die Implementierung von KI nicht nur von Innovationszielen, sondern maßgeblich auch von regulatorischen Anforderungen, Datenschutz und begrenzten Ressourcen bestimmt. Diese Rahmenbedingungen setzen voraus, dass die genutzte Basistechnologie nicht nur leistungsfähig, sondern auch konform und effizient gestaltet ist (Gan et al., 2023; Z. Li et al., 2024; Xu et al., 2024; Zhou et al., 2024).

Im Zentrum vieler generativer KI-Anwendungen stehen leistungsfähige Basismodelle, wie bereits in Kapitel 2.2.2 erläutert, deren Nutzung spezifische infrastrukturelle Anforderungen mit sich bringt. Somit werden für den produktiven Einsatz verschiedene Bereitstellungsformen unterschieden, darunter Cloud-basierte Modellendpunkte⁹, Edge-Inference-Systeme¹⁰ und hybride Architekturen¹¹ (Paaß & Giesselbach, 2023). Während serverbasierte Lösungen mit Grafikprozessoreinheiten (Graphics Processing Unit, GPU) die Grundlage für komplexe Foundation Models bilden, sind bei kleineren Modellen auch inferenzbasierte Verfahren auf Zentralprozessoreinheiten (Central Processing Unit, CPU) oder spezielle Hardware-Architekturen relevant – besonders dann, wenn Aspekte wie Kosten und Energieeffizienz im Vordergrund stehen (Andreoni et al., 2024). Neue Ansätze wie Processing-in-Memory und optimierte Datenplatzierungsstrategien ermöglichen es, auch in speicherlimitierten Umgebungen eine effiziente Nutzung zu realisieren (Ibrahim et al., 2024).

⁹ Siehe Anhang M für ausführliche Erläuterungen.

¹⁰ Ebd.

¹¹ Ebd.

Zunehmend werden für den dezentralen Einsatz Technologien wie Diffusionsmodelle und GAN optimiert. Dies erfolgt durch Latent Diffusion Models¹² oder Stable Diffusion-Varianten¹³, die auf Edge- und Server-Infrastruktur¹⁴ verteilt werden können. Für europäische Unternehmen, die lokale Datenverarbeitung zur Einhaltung der DSGVO bevorzugen, sind solche Ansätze besonders relevant. Allerdings erfordert die technische Umsetzung eine skalierbare Trainingsinfrastruktur und flexible Integrationsstrategien, um die Rechenlast effizient zu verteilen und die Qualität der generierten Inhalte sicherzustellen (Ibrahim et al., 2024; Z. Li et al., 2024; Paaß & Giesselbach, 2023). Im Gegensatz dazu ermöglichen Edge-Cloud-Umgebungen LLMs als Service zu nutzen, ohne selbst umfangreiche Infrastruktur aufbauen zu müssen. Dabei sind Task Offloading¹⁵ und In-Context-Learning zentrale Prinzipien, um Ressourcen optimal zwischen lokalen Systemen und der Cloud zu verteilen (Zhou et al., 2024).

Für die technische Integration in bestehende Systemlandschaften haben sich insbesondere Model-as-a-Service-Ansätze etabliert. Diese ermöglichen Unternehmen, auf vortrainierte Modelle über standardisierte Schnittstellen zuzugreifen und diese flexibel in ihre Geschäftsprozesse einzubinden. Der Vorteil liegt in der Reduktion des operativen Aufwands, da keine eigene Infrastruktur betrieben werden muss und die Integration über geläufige Entwicklerendpunkte erfolgt (Gan et al., 2023). Gleichzeitig bleibt die Herausforderung, Schnittstellen zu bestehenden Systemen im Unternehmen zu schaffen und die Interoperabilität sicherzustellen. Hierbei stellt das zentrale Datenmanagement ein bedeutsames Thema dar. Die Qualität, Verfügbarkeit und Sicherheit der Daten sind entscheidend für die Leistungsfähigkeit generativer KI (Glauner, 2024). Insbesondere europäische Unternehmen müssen dabei nicht nur technische, sondern auch regulatorische Anforderungen wie die DSGVO und den EU AI Act erfüllen. Dies erfordert robuste Governance-Strukturen, klare Verantwortlichkeiten für Datenzugriff und -verarbeitung sowie technische Maßnahmen zur Sicherstellung von Datenschutz und IT-Sicherheit (Ibrahim et al., 2024; Z. Li et al., 2024; Zhou et al., 2024).

Der Forschungsstand verdeutlicht, dass die technologische Infrastruktur ein Zusammenspiel aus leistungsfähigen Basismodellen, flexiblen Integrationsstrategien und einer sicheren, skalierbaren IT-Architektur erfordert. Dabei sollte die Auswahl und Kombination der Techno-

¹² Siehe Anhang M für ausführliche Erläuterungen.

¹³ Ebd.

¹⁴ Ebd.

¹⁵ Ebd.

logien stets an die spezifischen Ressourcen, Geschäftsprozesse und regulatorischen Rahmenbedingungen des jeweiligen Unternehmens angepasst werden. Vor diesem Hintergrund ist die Bedeutung von Bewertungskriterien, die nicht nur die technische Leistungsfähigkeit, sondern auch die betriebswirtschaftliche Relevanz und organisatorische Reife in den Fokus stellen, immanent.

Die verfügbare Basistechnologie bildet eine notwendige, jedoch keine hinreichende Bedingung für eine erfolgreiche KI-Implementierung – in der Praxis treten zusätzliche Hemmnisse auf, die im folgenden Kapitel dargelegt werden.

2.3.4 Hemmnisse der KI-Implementierung

Die Implementierung von KI-Anwendungen stellt insbesondere mittelständische Unternehmen vor spezifische Herausforderungen, die sich strukturell von jenen großer Unternehmen unterscheiden. Während Konzerne über spezialisierte KI-Einheiten, skalierbare Infrastrukturen und dedizierte Investitionsbudgets verfügen, die ihnen eine strukturell andere Ausgangslage verschaffen, müssen mittelständische Unternehmen KI-Implementierung unter engeren Ressourcenrestriktionen, höherer Personenabhängigkeit und geringerer Fehlertoleranz realisieren (Mesloh, 2021; Schönberger, 2023). Ein zentrales Hemmnis bilden begrenzte finanzielle und personelle Ressourcen: Investitionen in KI-Infrastruktur, Lizenzkosten sowie der Aufbau interner Kompetenzen übersteigen häufig die Kapazitäten mittelständischer Unternehmen (Mesloh, 2021; Rajaram & Tinguely, 2024). Eng damit verbunden ist der Mangel an qualifizierten Fachkräften mit KI-spezifischem Know-how, der den Aufbau notwendiger technischer und analytischer Fähigkeiten im Unternehmen erschwert (Oldemeyer et al., 2024). Hinzu kommen Unsicherheiten hinsichtlich des Return on Investment: Fehlende Methoden zur Erfolgsmessung und unklare Zielsetzungen führen dazu, dass viele Implementierungsinitiativen ohne valide Nutzenbewertung verbleiben (Bartelt & Röser, 2024a). Auf technologischer Ebene erweist sich die Integration in bestehende IT-Systemlandschaften – etwa ERP- oder CRM-Systeme – als komplex und ressourcenintensiv (Bartelt, 2024). Darüber hinaus erzeugen regulatorische Anforderungen im Bereich Datenschutz und Datensicherheit, insbesondere im Kontext des europäischen Rechtsrahmens, zusätzliche Unsicherheiten beim Einsatz von Drittanbieterlösungen (Ibrahim et al., 2024). Schließlich stellt die organisationale Dimension eine wesentliche Barriere dar: Mangelndes Vertrauen in die Technologie, Mitarbeiterwiderstand sowie fehlende Change-Management-

Kompetenzen behindern die nachhaltige Verankerung generativer KI in Unternehmensprozessen (Bettoni et al., 2021; Schwaeke et al., 2024).

Die dargelegten Hemmnisse verdeutlichen, dass KI-Implementierung über die bloße Überwindung technischer und organisationaler Barrieren hinausgeht. In der Forschung hat sich ein multidimensionales Verständnis etabliert, das technische, betriebswirtschaftliche und nutzerzentrierte Bewertungskriterien integriert und im folgenden Kapitel dargelegt wird.

2.4 Bewertungskriterien und Erfolgsfaktoren der KI-Implementierung

Die erfolgreiche Implementierung von KI-Anwendungen erfordert eine differenzierte Bewertung, die sowohl technische Leistungsmerkmale als auch betriebswirtschaftliche, organisatorische und nutzerzentrierte Aspekte berücksichtigt. Studien zeigen, dass sich in der Praxis ein multidimensionales Evaluationsverständnis etabliert hat, das technische Performance, Business Value, organisatorische Reife und kontinuierliche Überwachung integriert (Al-Khatib, 2024; Holmström & Carroll, 2025; Sonntag et al., 2024; Tawil et al., 2024; Wang & Zhang, 2025).

Im Zentrum der technischen Bewertung stehen praxisnahe, messbare Kriterien, die unmittelbar auf die Geschäftsprozesse wirken (Tawil et al., 2024). Besonders relevant sind dabei die Genauigkeit der Modelle und die aufgabenspezifische Leistungsfähigkeit, etwa bei der Empfehlungsgüte, der Qualität generierter Antworten oder der Erfolgsquote bei der automatisierten Bearbeitung von Aufgaben. Die Studie von Wang & Zhang (2025) verdeutlicht, dass Unternehmen weniger an generischen Benchmark-Werten interessiert sind, sondern vor allem an der konkreten Wirksamkeit im eigenen Anwendungskontext. Darüber hinaus sind Systemlatenz und Kosteneffizienz weitere Kriterien, da Unternehmen aufgrund begrenzter Ressourcen besonders sensibel auf Antwortzeiten und Betriebskosten reagieren. Moderne Evaluationsframeworks berücksichtigen bereits entsprechende Kosten-Nutzen-Aspekte als primäre technische Bewertungskategorie (Tawil et al., 2024). Ferner zählt die Integrationsfähigkeit von KI-Anwendungen in bestehende Systemlandschaften und Arbeitsabläufe als ergänzendes technisches Kriterium, zur Gewährleistung reibungsloser Prozesse und Interoperabilität (Wang & Zhang, 2025).

Neben der technischen Perspektive rücken ebenso nutzerzentrierte Kriterien in den Vordergrund. Die Effektivität und Effizienz der Systeme können nach ISO 9241¹⁶ anhand von

¹⁶ Die DIN ISO 9241 ist ein international anerkannter Standard für die Ergonomie der Mensch-System-Interaktion, der insbesondere im Kontext von KI-Implementierungen hohe Relevanz hat. Sie definiert Richtlinien

Kennzahlen wie Aufgabenerfüllungsrate, Fehlerquote und Bearbeitungszeit bewertet werden. Dem Forschungsstand ist zu entnehmen, dass Unternehmen insbesondere solche Lösungen bevorzugen, die einen geringen Schulungsaufwand erfordern und eine unmittelbare Nutzbarkeit bieten (Sonntag et al., 2024). Die Zufriedenheit der Nutzer*innen, ihre Akzeptanz und die wahrgenommene Nützlichkeit werden als Prädiktoren für den langfristigen Erfolg der Implementierung dargestellt. Systeme, die eine steile Lernkurve oder komplexe Bedienkonzepte aufweisen, werden in der Praxis seltener erfolgreich implementiert (Prasad Agrawal, 2024).

Die betriebswirtschaftliche Bewertung erfolgt vor allem anhand von Kennzahlen zur Prozessautomatisierung, Zeitersparnis und Produktivitätssteigerung. Studien aus dem produzierenden Mittelstand belegen, dass Effizienzgewinne und Automatisierungsraten als zuverlässige Indikatoren für den Erfolg von KI-Anwendungen genannt werden (Holmström & Carroll, 2025; Lawton et al., 2023). In Branchen wie Tourismus und Einzelhandel werden zudem Umsatzsteigerungen und Verbesserungen der Kundenbindung als zentrale Erfolgsgrößen herangezogen. Laut Deloitte-Studie berichten zwischen 18 % und 36 % der befragten Unternehmen, dass sie ihre mit KI verbundenen Zielsetzungen (u. a. Umsatz, Kosten, Effizienz, Innovation) zu einem großen oder sehr großen Anteil bereits erreicht haben (Deloitte, 2024). Ein weiterer Bewertungsmaßstab ist der Beitrag zur Innovation und zur Stärkung der Wettbewerbsfähigkeit. Unternehmen messen den Erfolg zunehmend daran, inwieweit neue Produkte, Dienstleistungen oder differenzierende Marktpositionierungen ermöglicht werden (Holmström & Carroll, 2025). Ebenso entscheidend sind Erfolgsgrößen wie Veränderungsbereitschaft und Reifegradmodelle, die die Bereitschaft zur KI-Implementierung entlang der Dimensionen Infrastruktur, Kompetenzen, Prozesse und Governance beeinflussen (Al-Khatib, 2024). Letztendlich ist es die Fähigkeit zum Change-Management, die Unterstützung durch das Top-Management und die kulturelle Passung der Organisation, die den nachhaltigen Erfolg der Implementierung ebnen (Lawton et al., 2023).

Nach der Einführung ist die kontinuierliche Überwachung und Anpassung der KI-Anwendungen ein integraler Bestandteil des Erfolgs (Sonntag et al., 2024; Wang & Zhang, 2025). Dazu gehören Feedbackschleifen, Performance-Analysen und die Bereitschaft, Systeme bei veränderten Rahmenbedingungen weiterzuentwickeln (Tawil et al., 2024). Der nachhaltige

für die nutzerzentrierte Gestaltung und Gebrauchstauglichkeit interaktiver Systeme, einschließlich KI-Anwendungen, um die Bedienbarkeit, Effizienz und Zufriedenheit der Nutzer*innen sicherzustellen sowie gesundheitliche Schäden zu vermeiden.

Erfolg von KI-Anwendungen beruht auf einem komplexen Zusammenspiel aus technischer Exzellenz, betriebswirtschaftlichem Mehrwert, Akzeptanz der Nutzer*innen und organisatorischer Reife. Unternehmen, die diese Dimensionen systematisch berücksichtigen, schaffen die Grundlage für eine wertschöpfende Nutzung. An dieser Stelle setzt die Entwicklung einer KI-Roadmap an, dessen Forschungsstand im nachfolgenden Kapitel dargelegt wird.

2.5 Entwicklung und Operationalisierung von KI-Roadmaps

In Unternehmen haben sich Roadmaps als Management-Instrument etabliert, um die Einführung und Skalierung von Technologien strategisch zu steuern (Aldoseri et al., 2024; Sonntag et al., 2024; Tawil et al., 2024). Angesichts begrenzter Ressourcen, fehlender technischer Expertise und teils mangelnder Erfahrung im strategischen Technologiemanagement stehen Unternehmen vor besonderen Herausforderungen bei der Planung und Umsetzung von KI-Anwendungen (Tawil et al., 2024; Waage et al., 2024). Demnach können KI-Roadmaps einen strukturierten Ansatz bieten, um diese Komplexität zu bewältigen und die Transformation von der ersten Standortbestimmung bis zur nachhaltigen Integration zu begleiten (Aldoseri et al., 2024; Tawil et al., 2024).

Ergebnisse aus Studien zeigen, dass erfolgreiche KI-Roadmaps typischerweise mit einer systematischen Bestandsaufnahme beginnen. Diese umfasst sowohl die Analyse der bestehenden IT- und Dateninfrastruktur als auch die Bewertung der organisatorischen Reife, der Kompetenzen und der strategischen Zielsetzungen (Tawil et al., 2024; Waage et al., 2024). Darauf aufbauend empfiehlt sich ein abgestufter Reifegradansatz, bei dem die Entwicklung von KI-Fähigkeiten in klar definierten Etappen erfolgt (Aldoseri et al., 2024; Lawton et al., 2023). Im Gegensatz zu groß angelegten Transformationsprojekten setzen sich in der Praxis inkrementelle Roadmap-Modelle durch, die auf kontinuierlicher Verbesserung und iterativer Umsetzung basieren (Sonntag et al., 2024; Tawil et al., 2024).

Ein Element moderner KI-Roadmaps ist der Einsatz von Canvas-Methoden und modularen Frameworks, die speziell auf die Bedürfnisse und Ressourcen von Unternehmen zugeschnitten sind (Lada et al., 2023; Lawton et al., 2023). Diese ermöglichen es, die wichtigsten Handlungsfelder – von der Use-Case-Identifikation über die Datenstrategie bis hin zu Governance- und Compliance-Fragen – übersichtlich zu strukturieren und zu priorisieren (Sonntag et al., 2024). Typische Inhalte einer KI-Roadmap umfassen demnach Meilensteine wie die

Auswahl und Validierung von Pilotprojekten, die Entwicklung von Daten- und IT-Kompetenzen, die Einführung von Change-Management-Maßnahmen sowie die schrittweise Skalierung erfolgreicher Anwendungen (Aldoseri et al., 2024; Tawil et al., 2024).

Die Operationalisierung der Roadmap erfolgt in der Regel entlang eines Pilot-to-Scale-Ansatzes. Nach der erfolgreichen Umsetzung erster Pilotprojekte werden diese systematisch evaluiert und bei nachgewiesenem Mehrwert auf weitere Geschäftsbereiche oder Prozesse ausgerollt (Sonntag et al., 2024; Tawil et al., 2024). Dieser Ansatz ermöglicht es, Risiken zu minimieren, Ressourcen gezielt einzusetzen und die Akzeptanz im Unternehmen schrittweise zu erhöhen (Aldoseri et al., 2024). Die kontinuierliche Überprüfung und Anpassung der Roadmap anhand von KPIs ist dabei ein relevanter Erfolgsfaktor (Lada et al., 2023).

Herausforderungen bei der Entwicklung und Umsetzung von KI-Roadmaps entstehen vor allem durch die erforderliche Verknüpfung technologischer, organisatorischer und regulatorischer Anforderungen (Tawil et al., 2024; Waage et al., 2024). Studien legen dar, dass eine enge Verzahnung dieser Anforderungen erforderlich ist, um die nachhaltige Verankerung von KI-Anwendungen im Unternehmen zu gewährleisten (Lawton et al., 2023; Sonntag et al., 2024). Kohärente Erfolgsfaktoren sind unter anderem die frühzeitige Einbindung aller relevanten Stakeholder, die Förderung einer innovationsfreundlichen Unternehmenskultur und die kontinuierliche Weiterentwicklung der Kompetenzen im Unternehmen (Aldoseri et al., 2024; Waage et al., 2024).

Für Unternehmen erweisen sich KI-Roadmaps schließlich als wirkungsvolles Instrument, um die Einführung generativer KI durch eine Kombination aus Standortbestimmung, Kompetenzentwicklung und iterativer Umsetzung systematisch zu gestalten. Sie bilden somit die praktische Grundlage für eine erfolgreiche digitale Transformation im Mittelstand. Um diese Erkenntnisse aus der Literatur zu fundieren und für die Framework-Entwicklung nutzbar zu gestalten, erfolgt in Kapitel 3 die theoretische und konzeptionelle Verankerung der Forschungsarbeit.

3 THEORETISCHE UND KONZEPTIONELLE VERANKERUNG

3.1 Systematik der Theorieauswahl und der konzeptionellen Integration

Das Fundament der Framework-Entwicklung bildet eine systematische Theorieauswahl, die der abduktiven Erkenntnislogik folgt (Peirce, 1997; Reichertz, 2013). Sie beinhaltet die Identifikation, Kategorisierung und Bewertung von Theorien und unterteilt sich in zwei Schritte, die innerhalb der nachfolgenden Abschnitte erläutert werden.

Im ersten Schritt werden Theorien identifiziert, die einen spezifischen Erklärungsbeitrag zum Forschungsgegenstand leisten können. Diese Vorgehensweise führt zu einer breiten, interdisziplinären Ansammlung von Ansätzen, die das Fundament des Folgeschritts darstellen, der eine Kategorisierung und Bewertung dieser vorsieht. Diesbezüglich bleiben jene Theorien unberücksichtigt, die eine mangelnde Passung zum Forschungsgegenstand, theoretische Redundanzen oder eine unzureichende Erklärungstiefe aufweisen. Die Kategorisierung erfolgt durch eine Einteilung in Kerntheorien, die als direkte gestalterische Grundlage für die Framework-Entwicklung dienen, und Kontexttheorien, die dessen wissenschaftliche Verankerung sicherstellen sollen. Parallel dazu wird ein Katalog aus sechs Bewertungskriterien angewendet, um Aspekte wie Anschlussfähigkeit, Erklärungskraft und Praxisrelevanz systematisch zu beurteilen.

Das Ergebnis dieser Vorgehensweise ist ein ausgewähltes, theoretisches Fundament, das durch die Kerntheorien die direkte Konstruktion des Frameworks anleitet und durch die Kontexttheorien dessen wissenschaftliche Einbettung und Legitimität sicherstellt. Zur Wahrung von Nachvollziehbarkeit und Transparenz, erläutert Kapitel 3.1.1 die Kategorisierungscharakteristika, anhand derer die Theorien unterteilt werden, um ihre spezifische Funktion für das Framework zu bestimmen. Darauf aufbauend stellt Kapitel 3.1.2 die Ableitung der Bewertungskriterien vor.

3.1.1 Erläuterung der Kategorisierungscharakteristika

Im Rahmen der Framework-Entwicklung fungieren Kerntheorien als sogenannte „arbeitende Theorien“. Sie bilden die unmittelbare Gestaltungsgrundlage und liefern praxisnahe Empfehlungen für die operative Ausgestaltung der Framework-Entwicklung (Nilsen, 2015). Ihr besonderer Wert liegt in der direkten Anwendbarkeit: Diese Theorien sind anschlussfähig und bieten klare Handlungsanleitungen, die unmittelbar in die Architektur und Prozessgestaltung einfließen können (Damschroder et al., 2009; Gregor & Hevner, 2013).

Ergänzend dazu werden Kontexttheorien als „legitimierende Theorien“ herangezogen, um das Implementierungsframework wissenschaftlich zu fundieren und in einen breiteren theoretischen Diskurs einzubetten (Nilsen, 2015). Diese Theorien können zur analytischen Durchdringung beitragen, indem sie die zugrundeliegenden Phänomene und Mechanismen der Implementierung theoretisch erklären und einordnen. Dadurch wird nicht nur die Glaubwürdigkeit der Framework-Entwicklung gestärkt, sondern auch eine Generalisierung der gewonnenen Erkenntnisse ermöglicht (Birken et al., 2023; Kislov et al., 2019).

3.1.2 Ableitung von Bewertungskriterien

Die Entwicklung der Bewertungskriterien folgt etablierten Standards der organisationalen Forschung mit dem Ziel, methodische Rigorosität und praktische Anwendbarkeit zu gewährleisten. Dieser Ableitungsprozess mündet in die Definition der folgenden Kriterien in Tabelle 5.

Tabelle 5: Bewertungskriterien zur Theorieauswahl

Kürzel	Kurze Erläuterung
(K1)	Direkte empirische Anschlussfähigkeit
(K2)	Erklärungskraft für beobachtete Phänomene
(K3)	Praxisrelevanz für die Gestaltung eines adaptiven Frameworks
(K4)	Beitrag zur wissenschaftlichen Fundierung
(K5)	Interdisziplinarität und Fähigkeit zur Integration verschiedener Systemebenen
(K6)	Eignung zur Bewältigung von Unsicherheit, Wandel und offenen Entwicklungsprozessen

Quelle: Eigene Darstellung

Bewertungskriterium K1:

Das erste Bewertungskriterium der „direkten Anschlussfähigkeit“ basiert auf den Prinzipien der empirisch fundierten Theorieentwicklung nach Eisenhardt (1989). Demzufolge müssen Theorien eine direkte Verbindung zu den identifizierten Herausforderungen und Mustern gegenüber dem Forschungsgegenstand aufweisen. Dies umfasst die Fähigkeit, beobachtete Phänomene wie iterative Implementierungszyklen, kontextspezifische Anpassungen und die Integration verschiedener Stakeholder-Perspektiven theoretisch zu erklären.

Bewertungskriterium K2:

Als zweites Bewertungskriterium fungiert die „Erklärungskraft für beobachtete Phänomene“, welche sich an den Anforderungen prozessualer Organisationsforschung (Pettigrew,

1997) orientiert. Spezifische Erklärungsbeiträge für beobachtete Charakteristika stehen hierbei im Fokus, insbesondere für Iterativität, Kontextsensitivität und die Integration technischer, organisatorischer sowie kultureller Faktoren. Die Erklärungskraft wird anhand der Fähigkeit bewertet, komplexe Implementierungsdynamiken theoretisch zu durchdringen.

Bewertungskriterium K3:

Die „Praxisrelevanz für die Gestaltung eines adaptiven Frameworks“ bildet das dritte zentrale Bewertungskriterium und folgt den Prinzipien angewandter Organisationsforschung nach Van de Ven (2007). Praktische Implikationen für die Entwicklung eines übertragbaren und partizipativen Ansatzes sind dabei von zentraler Bedeutung. Dies beinhaltet die Fähigkeit, konkrete Gestaltungsempfehlungen abzuleiten und dabei spezifische Ressourcenbeschränkungen und organisationale Charakteristika zu berücksichtigen.

Bewertungskriterium K4:

Das vierte Bewertungskriterium des „Beitrags zur wissenschaftlichen Fundierung“ basiert auf den Standards der Theorieentwicklung in der Managementforschung (Sutton & Staw, 1995; Whetten, 1989). Dabei werden ein substantieller Beitrag zur wissenschaftlichen Fundierung sowie eine Differenzierung von generischen Implementierungsmodellen vorausgesetzt. Dies umfasst die Fähigkeit, neue theoretische Einsichten für die Implementierungsforschung zu generieren und bestehende Theorien kontextuell zu erweitern.

Bewertungskriterium K5:

Als fünftes Bewertungskriterium wird die „Interdisziplinarität und Fähigkeit zur Integration verschiedener Systemebenen“ festgelegt, welche sich an den Anforderungen komplexer Organisationsphänomene nach Lewis & Grimes (1999) orientiert. Die Integration verschiedener Analyseebenen und interdisziplinärer Perspektiven steht dabei im Mittelpunkt der Bewertung. Dies ist essenziell für die ganzheitliche Erfassung der Implementierung als sozio-technisches Phänomen.

Bewertungskriterium K6:

Das sechste und abschließende Bewertungskriterium ist die „Eignung zur Bewältigung von Unsicherheit, Wandel und offenen Entwicklungsprozessen“. Hierfür erforderlich sind konzeptuelle Ansätze für den Umgang mit technologischer Unsicherheit, organisationalem Wandel und emergenten Entwicklungsprozessen (Kapoor & Klueter, 2021). Dies umfasst die Fähigkeit, adaptive und flexible Ansätze theoretisch zu fundieren.

Auf Grundlage der beschriebenen Bewertungskriterien erfolgt in den Kapiteln 3.3.1 und 3.3.2 ihre Anwendung. Das Ziel besteht darin, diejenigen theoretischen Ansätze zu identifizieren, die sowohl wissenschaftlichen Anspruch als auch praktische Relevanz für das zu entwickelnde Implementierungsframework vereinen. Zudem wird eine 4-stufige Skala eingesetzt, um die Bewertung in ein messbares sowie vergleichbares Format zu überführen. Die jeweiligen Skalenwerte setzen sich wie folgt zusammen: 1 = trifft nicht zu, 2 = trifft teilweise zu, 3 = trifft überwiegend zu, 4 = trifft voll zu. Es wurde bewusst auf eine neutrale Mitte verzichtet, um eine klare Tendenz zur Zustimmung oder Ablehnung zu erhalten.

3.2 Erster Schritt: Identifikation der theoretischen Basis

Für die Identifikation relevanter Theorien wird eine breite theoretische Perspektive eingenommen, die verschiedene Forschungsdisziplinen umfasst. Dies soll der Komplexität der KI-Implementierung entgegenkommen, die sowohl technische, organisationale, strategische als auch kulturelle Aspekte umfasst und daher nicht durch einzelne Theorien vollständig erfasst werden kann.

Das Quality Implementation Framework nach Fixsen et al. (2005) stellt erste anwendbare Erklärungsansätze für verschiedene Phasen eines Implementierungsprozesses bereit. Es identifiziert vier sequenzielle, aber sich überschneidende Implementierungsstufen – Exploration, Installation, Initial Implementation und Full Implementation – die jeweils spezifische Aktivitäten und Erfolgskriterien umfassen. Dahingegen erklärt die Diffusion-of-Innovations-Theory (Rogers, 2003) die beobachteten Adoptions- und Diffusionsmuster, insbesondere die Rolle von Innovationsbereitschaft, frühen Tests und Feedbackschleifen bei der organisationsweiten Ausbreitung von Technologien. Eine weitere identifizierte Theorie ist das Drei-Phasen-Modell des Wandels nach Lewin (1947). Dieses Modell beschreibt Veränderung als Prozess aus dem Aufbrechen bestehender Strukturen (Unfreezing), dem Übergang zu neuen Praktiken (Moving) und der Verfestigung dieser Neuerungen in der Organisation (Refreezing). Ergänzend hierzu erklärt das Acht-Stufen-Modell nach Kotter (1996) die Notwendigkeit von Kommunikation, Beteiligung und Verankerung neuer Praktiken, die als kritische Erfolgsfaktoren identifiziert werden.

Weitere Ansätze sind agile und iterative Prozessmodelle, die empirische, experimentelle und adaptive Vorgehensweisen zur Framework-Entwicklung theoretisch fundieren können. Agile Methoden wie Scrum und Design Thinking erklären die Betonung von Prototyping, Feedback und kontinuierlicher Anpassung in Implementierungsprozessen. Ergänzend hierzu

betont die Lean-Startup-Methodology nach Ries (2011) das Build-Measure-Learn-Prinzip, bei dem über Minimum Viable Products (MVPs) Hypothesen zu Anwendungsfällen möglichst frühzeitig getestet und validiertes Lernen erzeugt wird.

Eine weitere Grundlage stellt die Soziotechnische Systemtheorie nach Trist und Bamforth (1951) dar, die die Verzahnung von technischen, organisatorischen und kulturellen Faktoren im Implementierungsprozess erklären kann. Diese Theorie fordert die gleichwertige Berücksichtigung technischer und sozialer Dimensionen und bietet die Basis für das Verständnis der Komplexität von KI-Implementierungen. Ebenso sind adaptive und lernende Organisationen zu berücksichtigende Ansätze, die die Prozessarchitektur als lernenden Zyklus mit kontinuierlichen Rückkopplungen erklären. Ergänzend dazu bietet das Konzept der lernenden Organisation nach Senge (1990) eine theoretische Fundierung für beobachtete kontinuierliche Anpassungsprozesse. Vertiefend dazu erklärt die Dynamic-Capabilities-Theory nach Teece et al. (1997) die Fähigkeit von Unternehmen, Prozesse und Strukturen flexibel an neue technologische und organisationale Anforderungen anzupassen.

Zur Erläuterung von Akzeptanz- und Nutzungsmustern, können Akzeptanz- und Adoptionsmodelle herangezogen werden. Demzufolge bietet das Technology-Acceptance-Model (TAM) nach Davis (1989) eine theoretische Grundlage für das Verständnis der wahrgenommenen Nützlichkeit und Benutzerfreundlichkeit von KI-Anwendungen. Sie kann die beobachteten Unterschiede in der Akzeptanz und die Bedeutung von Benutzerfreundlichkeit für die organisationsweite Verbreitung erklären. Ebenso kann die Balanced Scorecard nach Kaplan und Norton (1996) einen konzeptionellen Rahmen für die systematische Messung und Steuerung der KI-Implementierung über verschiedene Perspektiven hinweg – von finanziellen Kennzahlen über Kundenperspektiven bis hin zu internen Prozessen sowie Lern- und Entwicklungsaspekten – bieten.

Letztlich offeriert das Technology-Organization-Environment (TOE) Framework nach Tornatzky und Fleischer (1990) einen strukturierten Analyserahmen für die systematische Betrachtung der Einflussfaktoren auf Implementierungsprozesse. Es kategorisiert die Determinanten der Technologieadoption in drei zentrale Kontextdimensionen: technologische Faktoren, organisationale Faktoren sowie Umweltfaktoren. Ergänzend dazu erklärt die emergente Strategie nach Mintzberg (1985) die beobachtete Notwendigkeit adaptiver und lernorientierter Implementierungsansätze in dynamischen technologischen Umfeldern. Im Gegensatz zu alternativen Planungsansätzen betont die emergente Strategie (Mintzberg & Waters, 1985) kontinuierliche Lernprozesse, Bottom-up-Entwicklungen und die Fähigkeit

zur flexiblen Anpassung an unvorhergesehene Herausforderungen während der Implementierung.

Eine solche breite theoretische Basis gewährleistet, dass verschiedene Dimensionen bei der KI-Implementierung angemessen untersucht und etablierte Erklärungsansätze in die Framework-Entwicklung einfließen können. Allerdings erfordert dies eine Fokussierung auf jene Ansätze, die sowohl theoretische Erklärungskraft als auch praktische Gestaltungsrelevanz gegenüber dem Forschungsgegenstand vorweisen können. Daher wird eine systematische Bewertung und Kategorisierung im nachfolgenden zweiten Schritt durchgeführt, um ihre spezifischen Beiträge zur Framework-Entwicklung zu identifizieren und eine kohärente Integration zu ermöglichen.

3.3 Zweiter Schritt: Kategorisierung und Bewertung der theoretischen Basis

3.3.1 Kerntheorien und ihre Bewertung für die Framework-Entwicklung

Das TOE-Framework nach Tornatzky & Fleischer (1990) wird als Kerntheorie kategorisiert, da es eine systematische und empirisch validierte Struktur für die Analyse komplexer Technologieimplementierungen bereitstellt. Die Theorie erfüllt die Bewertungskriterien (K1), (K3), (K4) und (K5) durch ihre Praxisrelevanz in der Technologieadoption und ihre direkte Anwendbarkeit auf die KI-Implementierung. Zudem bietet das Framework eine strukturierte Herangehensweise zur Analyse der drei zentralen Einflussdimensionen: technologische Faktoren (Kompatibilität, Komplexität, relative Vorteile), organisationale Faktoren (Größe, Struktur, Ressourcen) und umweltbezogene Faktoren (Wettbewerbsdruck, regulatorische Rahmenbedingungen). Demnach liegt der Framework-Beitrag in der Bereitstellung eines multidimensionalen Analyserasters, das eine systematische Bewertung der Implementierungsvoraussetzungen ermöglicht. Somit unterstützt das TOE-Framework (Tornatzky & Fleischer, 1990) die Entwicklung kontextsensitiver Implementierungsstrategien, die spezifische Charakteristika mittelständischer Unternehmen berücksichtigen und eine strukturierte Herangehensweise an die Komplexität generativer KI gewährleisten.

Die Soziotechnische Systemtheorie nach Trist & Bamforth (1951) fungiert als Kerntheorie durch ihre Erkenntnis der gleichwertigen Integration technischer und sozialer Subsysteme bei Technologieimplementierungen. Sie erfüllt die Bewertungskriterien (K1), (K2) und (K5) durch ihre hohe Relevanz für die Gestaltung von Mensch-Technik-Interaktionen und durch ihre Fundierung in zahlreichen Organisationsstudien. Außerdem ist sie direkt anwendbar auf die KI-Implementierung, die sowohl technische als auch soziale Transformationen erfordert.

Die Systemtheorie betont die Notwendigkeit einer ausgewogenen Optimierung von Subsystemen zur Erreichung optimaler Systemleistung. Ihr Beitrag zur Framework-Entwicklung besteht in der theoretischen Fundierung ganzheitlicher Gestaltungsprinzipien, die sowohl technische Funktionalität als auch soziale Akzeptanz gewährleisten. Somit unterstützt der soziotechnische Ansatz (Trist & Bamforth, 1951) die Entwicklung ausgewogener Framework-Komponenten, die Mensch-Technik-Interaktionen optimieren und die Integration von Technologie in bestehende Arbeitsstrukturen ermöglicht. Zudem stellen Trist & Bamforth (1951) eine konzeptuelle Grundlage für die Gestaltung partizipativer Implementierungsprozesse und die Berücksichtigung sozialer Faktoren bei der Technologieeinführung.

Als weitere Kerntheorie wird die Dynamic-Capabilities-Theory nach Teece et al. (1997) aufgrund ihrer direkten Anwendbarkeit auf die Gestaltung adaptiver Implementierungsprozesse in dynamischen Umgebungen eingestuft. Die Theorie erfüllt die Bewertungskriterien (K2), (K3) und (K6) durch ihre Relevanz für organisationale Anpassungsfähigkeit und ihre spezifische Eignung für die Implementierung disruptiver Technologien wie generativer KI. Teece et al. (1997) konzeptualisieren organisationale Fähigkeiten zur Identifikation, Entwicklung und Rekonfiguration von Ressourcen als Reaktion auf sich verändernde Umweltbedingungen. Ihr Ansatz ermöglicht die Integration von Lern- und Anpassungsmechanismen in die Framework-Architektur und unterstützt die Entwicklung organisationaler Kompetenzen für das Management technologischer Transformationen. Zudem wird eine Grundlage für die Gestaltung adaptiver Governance-Strukturen und die Entwicklung von Fähigkeiten zur kontinuierlichen Innovation und Verbesserung geboten. Der Framework-Beitrag liegt in der theoretischen Fundierung von Fähigkeiten zur kontinuierlichen Anpassung und Weiterentwicklung von KI-Implementierungen.

Die Diffusion-of-Innovations-Theory nach Rogers (2003) fungiert durch ihre operationalisierbaren Konzepte für Adoptions- und Diffusionsprozesse ebenso als Kerntheorie, die direkt auf KI-Implementierungen anwendbar ist. Rogers' Theorie (2003) erfüllt die Bewertungskriterien (K1), (K2), (K4) und (K5) durch ihre Praxisrelevanz für Technologieadoptionsprozesse und ihre spezifische Eignung für die Analyse der Verbreitung komplexer Innovationen. Sein Ansatz identifiziert fünf zentrale Innovationscharakteristika (relative Vorteile, Kompatibilität, Komplexität, Erprobbarkeit, Beobachtbarkeit) und unterscheidet verschiedene Adopter-Kategorien mit spezifischen Charakteristika. Demzufolge besteht der Beitrag zur Framework-Entwicklung in der Bereitstellung phasenspezifischer Implementierungsstrategien und der systematischen Berücksichtigung von Adopter-Charakteristika. Auf

dieser theoretischen Grundlage können zielgruppenspezifische Framework-Komponenten entwickelt und differenzierte Kommunikations- und Unterstützungsstrategien gestaltet werden. Letztlich wird eine Grundlage für die Sequenzierung von Implementierungsaktivitäten und die Identifikation kritischer Erfolgsfaktoren für die organisationsweite Verbreitung von KI-Technologien bereitgestellt.

Abschließend wird die Emergente Strategie von Mintzberg (1985) als Kerntheorie kategorisiert, da sie eine Basis für flexible, anpassungsfähige Implementierungsansätze in unsicheren Umgebungen bietet. Die Theorie erfüllt die Bewertungskriterien (K2), (K3), (K5) und (K6) durch ihre Relevanz für strategische Entscheidungsprozesse unter Unsicherheit, ihre Fundierung in der Strategieforschung und ihre spezifische Eignung für die Implementierung disruptiver Technologien. Die Theorie unterscheidet zwischen geplanten und emergenten strategischen Elementen und betont die Bedeutung adaptiver Lernprozesse bei der Strategieentwicklung. Der Framework-Beitrag liegt in der theoretischen Fundierung iterativer Planungs- und Anpassungsprozesse, die Unsicherheit und Wandel als zentrale Charakteristika der KI-Implementierung berücksichtigen. Mintzbergs Ansatz (1985) ermöglicht die Gestaltung adaptiver Framework-Strukturen, die sowohl strategische Planung als auch opportunistische Anpassungen integrieren. Ferner unterstützt er die Entwicklung flexibler Governance-Mechanismen und liefert die Grundlage für die Balance zwischen strategischer Ausrichtung und operativer Flexibilität bei der KI-Implementierung.

Die nachfolgende Tabelle 6 fasst die zentralen Aspekte der vorgestellten Kerntheorien zusammen und stellt deren jeweiligen Beitrag für die Framework-Entwicklung vergleichend gegenüber.

Tabelle 6: Überblick und Beitrag der Kerntheorien zur Framework-Entwicklung

Kerntheorie (Autor, Jahr)	Erfüllte Bewertungskriterien	Zentrale Aspekte der Theorien	Beitrag zur Framework-Entwicklung
TOE-Framework (Tornatzky & Fleischer, 1990)	(K1), (K3), (K4), (K5)	Analyse von Technologieimplementierungen anhand von drei Dimensionen: Technologie, Organisation und Umwelt (Environment).	Bereitstellung eines multidimensionalen Analyserasters zur systematischen Bewertung der Implementierungsvoraussetzungen.
Soziotechnische Systemtheorie (Trist & Bamforth, 1951)	(K1), (K2), (K5)	Gleichwertige Integration und Optimierung von technischen und sozialen Subsystemen für eine optimale Gesamtleistung.	Theoretische Fundierung für ganzheitliche Gestaltungsprinzipien, die technische Funktionalität und soziale Akzeptanz sicherstellen.
Dynamic-Capabilities-Theory (Teece et al., 1997)	(K2), (K3), (K6)	Fähigkeit einer Organisation, Ressourcen als Reaktion auf Umweltveränderungen zu identifizieren, zu entwickeln und zu rekonfigurieren.	Fundierung von Fähigkeiten zur kontinuierlichen Anpassung und Weiterentwicklung der KI-Implementierung; Integration von Lernmechanismen.
Diffusion-of-Innovations-Theory (Rogers, 2003)	(K1), (K2), (K4), (K5)	Erklärung von Adoptions- und Diffusionsprozessen durch Innovationscharakteristika und Adopter-Kategorien.	Grundlage für phasenspezifische und zielgruppengerechte Implementierungs-, Kommunikations- und Unterstützungsstrategien.
Emergente Strategie (Mintzberg, 1985)	(K2), (K3), (K5), (K6)	Strategie als ein Muster, das aus geplanten und ungeplanten (emergenten) Aktionen entsteht; Betonung von adaptivem Lernen.	Theoretische Basis für iterative Planungs- und Anpassungsprozesse; ermöglicht die Balance zwischen strategischer Planung und operativer Flexibilität.

Quelle: Eigene Darstellung

Die Darstellung verdeutlicht, wie die ausgewählten Theorien eine komplementäre und robuste Grundlage für das zu entwickelnde Framework bilden. Sie decken sowohl strukturelle als auch prozessuale und adaptive Aspekte der Implementierung ab. Aufbauend auf diesem Fundament werden im folgenden Kapitel nun die unterstützenden Theorien erörtert, die diese Kernperspektiven gezielt ergänzen.

3.3.2 Kontexttheorien und ihre Bewertung für die wissenschaftliche Verankerung

Die Lean-Startup-Methodology nach Ries (2011) wird als Kontexttheorie eingeordnet, da es das Framework wissenschaftlich in der Tradition experimenteller, iterativer Innovationsansätze verankert und theoretische Legitimation für adaptive Implementierungsstrategien bietet. Die Theorie erfüllt die Bewertungskriterien (K1), (K2), (K3) und (K6) durch ihre Praxisrelevanz in der Produktentwicklung und ihre Anwendbarkeit auf innovative Technologieprojekte. Hervorzuheben ist die Bedeutung von Hypothesenbildung, schnellem Prototyping und kontinuierlichem Lernen bei der Entwicklung neuer Produkte und Dienstleistungen. Der Beitrag zur wissenschaftlichen Verankerung liegt in der theoretischen Legitimation

adaptiver Vorgehensweisen und der wissenschaftlichen Fundierung von Build-Measure-Learn-Zyklen für KI-Implementierungen. Ries' Ansatz (Ries, 2011) begründet experimentelle Vorgehensweisen theoretisch und liefert konzeptuelle Grundlagen für die Integration von Feedback-Mechanismen und iterativen Verbesserungsprozessen in das Framework-Design.

Kotters Acht-Stufen-Modell des Wandels (1996) fungiert als weitere Kontexttheorie durch seine etablierte Position in der Change-Management-Forschung und seine wissenschaftliche Fundierung systematischer Veränderungsprozesse. Es erfüllt die Bewertungskriterien (K1), (K2), (K3) und (K4) durch seine Praxisrelevanz für organisationale Transformationen und seine Anwendbarkeit auf technologieinduzierte Veränderungsprozesse. Das Modell strukturiert Veränderungsprozesse in acht aufeinander aufbauende Phasen und betont die Bedeutung von Führung, Kommunikation und Partizipation. Der Beitrag zur wissenschaftlichen Verankerung besteht in der theoretischen Legitimation systematischer Veränderungsprozesse und der wissenschaftlichen Fundierung kommunikativer sowie partizipativer Framework-Elemente. Durch Kotters Ansatz (1996) lassen sich theoretische Grundlagen für die Gestaltung von Change-Management-Komponenten schaffen und strukturierte Implementierungsansätze wissenschaftlich begründen.

Die Balanced Scorecard nach Kaplan & Norton (1996) wird ebenso als Kontexttheorie kategorisiert, da sie das Framework wissenschaftlich in der Tradition multidimensionaler Performance-Messung verankert und theoretische Legitimation für ganzheitliche Bewertungsansätze bietet. Sie erfüllt die Bewertungskriterien (K1), (K2) und (K4) durch ihre strukturierte Herangehensweise an organisatorische Performance-Bewertung und ihre Anwendbarkeit auf komplexe Transformationsprojekte. Kaplan und Norton integrieren vier zentrale Performance-Perspektiven: Kundenperspektive, Finanzperspektive, Entwicklungsperspektive sowie interne Prozessperspektive. Ihr Beitrag liegt in der theoretischen Legitimation multidimensionaler Bewertungsansätze und der wissenschaftlichen Fundierung ausgewogener Performance-Messung. Durch das Scorecard-Konzept lassen sich ganzheitliche Erfolgsmessungen theoretisch begründen und Konzeptionsgrundlagen für die Integration verschiedener Bewertungsdimensionen schaffen, wobei der Beitrag primär auf die Erfolgsmessung und strategische Steuerung beschränkt ist.

Abschließend fungiert das TAM nach Davis (1989) als Kontexttheorie durch seine wissenschaftliche Verankerung in der Technologieakzeptanzforschung und seine theoretische Erklärung individueller Adoptionsentscheidungen. Das Modell erfüllt die Bewertungskriterien

(K1), (K2), (K3) und (K4) durch ihre hohe Relevanz für Technologieakzeptanz und ihre Anwendbarkeit auf komplexe IT-Systeme. Das Modell identifiziert wahrgenommene Nützlichkeit und wahrgenommene Benutzerfreundlichkeit als zentrale Determinanten der Technologieakzeptanz. Der Framework-Beitrag besteht in der theoretischen Erklärung individueller und organisationaler Akzeptanzprozesse sowie der wissenschaftlichen Fundierung nutzerzentrierter Framework-Komponenten. Sowohl theoretische Grundlagen für akzeptanzfördernde Maßnahmen als auch die wissenschaftliche Begründung nutzerzentrierter Implementierungsansätze werden durch die Theorie bereitgestellt.

Die folgende Tabelle 7 fasst die vorgestellten Kontexttheorien zusammen und verdeutlicht ihren spezifischen Beitrag zur Verankerung des Frameworks in etablierten Forschungssträngen.

Tabelle 7: Überblick und Beitrag der Kerntheorien zur Framework-Entwicklung

Kontexttheorie (Autor, Jahr)	Erfüllte Bewertungskriterien	Zentrale Aspekte der Theorien	Beitrag zur Framework-Entwicklung
Lean-Startup-Methodology (Ries, 2011)	(K1), (K2), (K3), (K6)	Experimenteller, iterativer Innovationsansatz mittels Build-Measure-Learn-Zyklen.	Legitimation adaptiver Vorgehensweisen und Fundierung von Feedback-Mechanismen und iterativen Verbesserungsprozessen.
Acht-Stufen-Modell (Kotter, 1996)	(K1), (K2), (K3), (K4)	Strukturierter, phasenbasierter Ansatz für das Management organisationaler Veränderungsprozesse.	Legitimation systematischer Change-Management-Prozesse und Fundierung kommunikativer sowie partizipativer Framework-Elemente.
Balanced Scorecard (Kaplan & Norton, 1996)	(K1), (K2), (K4)	Multidimensionale Performance-Messung anhand von vier Perspektiven (Finanzen, Kunden, Prozesse, Lernen).	Legitimation ganzheitlicher Bewertungsansätze und Fundierung einer ausgewogenen, multidimensionalen Erfolgsmessung.
Technology Acceptance Model (TAM) (Davis, 1989)	(K1), (K2), (K3), (K4)	Erklärung der Technologieakzeptanz durch die zentralen Faktoren der wahrgenommenen Nützlichkeit und Benutzerfreundlichkeit.	Theoretische Erklärung von Akzeptanzprozessen und wissenschaftliche Begründung für die Gestaltung nutzerzentrierter Maßnahmen.

Quelle: Eigene Darstellung

Schließlich liefern die dargestellten Kontext- sowie Kerntheorien die wissenschaftliche Fundierung für die Entwicklung des Implementierungsframeworks in Kapitel 5.3. Sie verdeutlichen, welche theoretischen Modelle und Ansätze zur Implementierung von generativer KI in mittelständischen Unternehmen beitragen und wie diese in ein kohärentes Konzept integriert werden können. Im nächsten Schritt führt Kapitel 4 in die methodische Umsetzung ein, um die Überführung der theoretischen Grundlagen in die Framework-Entwicklung einzuleiten.

4 METHODIK

4.1 Systematik des Forschungsdesigns und theoretische Fundierung

Das folgende Kapitel legt die methodische Vorgehensweise dieser Forschungsarbeit dar. Es beginnt mit einer Erläuterung der Systematik des Forschungsdesigns und des zugrundeliegenden Forschungsparadigmas. Der Schwerpunkt liegt jedoch auf der detaillierten Beschreibung des dreiphasigen Forschungsprozesses. Dieser umfasst die Rekrutierung und Datensammlung (Phase 1), die Entwicklung eines ersten Framework-Entwurfs (Phase 2) und die Validierung und finalen Überarbeitung (Phase 3). Ziel des Kapitels ist es, ein transparentes und wissenschaftlich fundiertes Vorgehen zu dokumentieren, das die Nachvollziehbarkeit der Ergebnisse sicherstellt.

Das Ziel dieser Forschungsarbeit ist die Entwicklung eines praxisorientierten Implementierungsframeworks für generative KI im deutschen Mittelstand. Die Neuartigkeit des Forschungsgegenstandes und die Komplexität der damit verbundenen organisationalen Transformationen erfordern eine spezifische methodologische Herangehensweise. Da generative KI-Technologien erst in den letzten Jahren für mittelständische Unternehmen zugänglich geworden sind (Lemos et al., 2022; Rajaram & Tinguely, 2024), werden etablierte Implementierungsmodelle nur begrenzt angewendet (Creswell et al., 2018). Zudem induziert die Implementierung generativer KI umfassende Veränderungen in Arbeitsabläufen, Entscheidungsstrukturen und der Unternehmenskultur (Schwaeke et al., 2024). Vor diesem Hintergrund ist die Forschungsarbeit der pragmatistischen Erkenntnistheorie zuzuordnen, bei der die Forschungsfragen als primärer Bestimmungsfaktor für die methodologische Ausrichtung dienen (Feilzer, 2010). Diese Perspektive erkennt die praktische Nützlichkeit von Wissen als zentrales Validitätskriterium an und legitimiert die Kombination verschiedener methodischer Ansätze, um die Forschungsfragen angemessen zu beantworten (Maarouf, 2019).

Der Forscher nimmt eine aktive Rolle im Erkenntnisprozess ein, die zur Entwicklung eines praktisch nutzbaren Implementierungsframeworks beitragen soll. Die Erkenntnisgewinnung erfolgt durch die systematische Kombination induktiver, deduktiver und abduktiver Verfahren, wobei die abduktive Erkenntnislogik als methodologischer Bezugsrahmen für die iterative Framework-Entwicklung fungiert. Diese Entwicklung vollzieht sich in zyklischen Abfolgen zwischen theoretischer Konzeption und empirischer Beobachtung, wodurch eine kontinuierliche Verfeinerung des Implementierungsframeworks gewährleistet werden soll (Jabareen, 2009).

Die Vorgehensweise und der damit verbundene Aufbau der Forschungsarbeit folgen einem qualitativ-explorativen Ansatz. Zu Beginn erfolgt die systematische und nachvollziehbare Auswahl von Expert*innen unter Zuhilfenahme eines Scoring-Modells sowie die Durchführung einer Dokumentenrecherche (Abbildung 3, Phase 1).

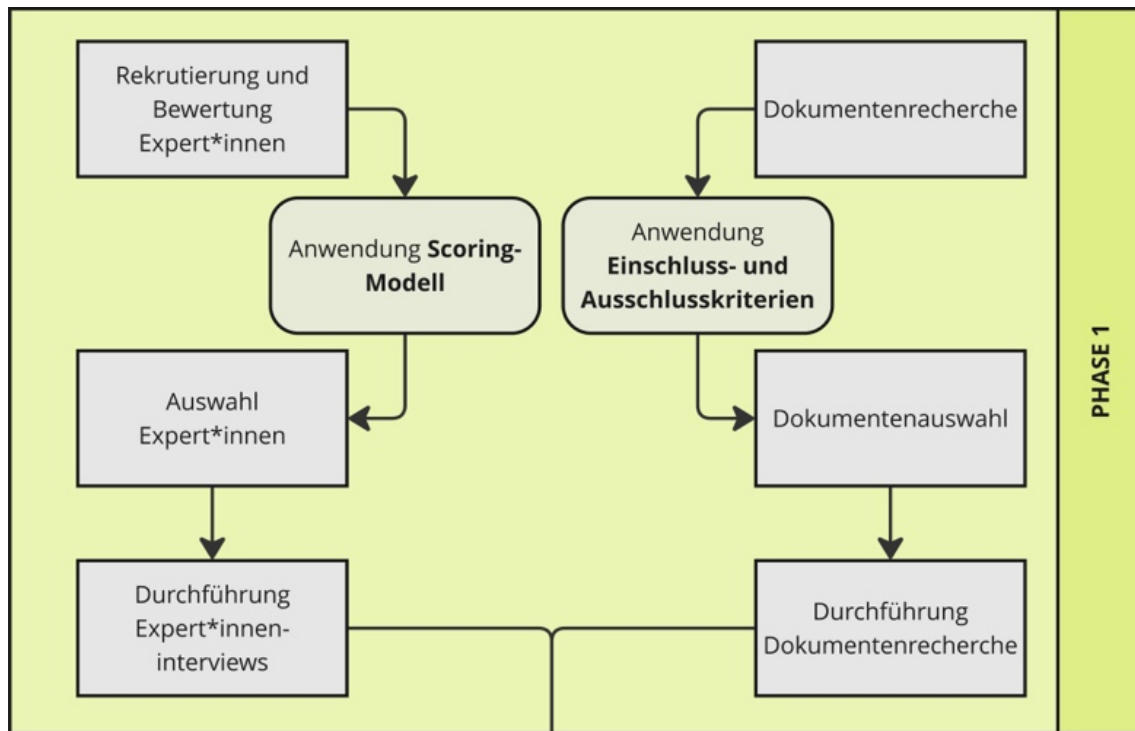


Abbildung 3: Phase 1 des Forschungsprozesses

Quelle: Eigene Darstellung

Anschließend ermöglicht die qualitative Inhaltsanalyse nach Kuckartz (2018) in induktiver sowie deduktiv-induktiver Form eine sowohl datengeleitete Kategorienbildung als auch theoriegeleitete Kontextualisierung der Ergebnisse (Abbildung 4, Phase 2).

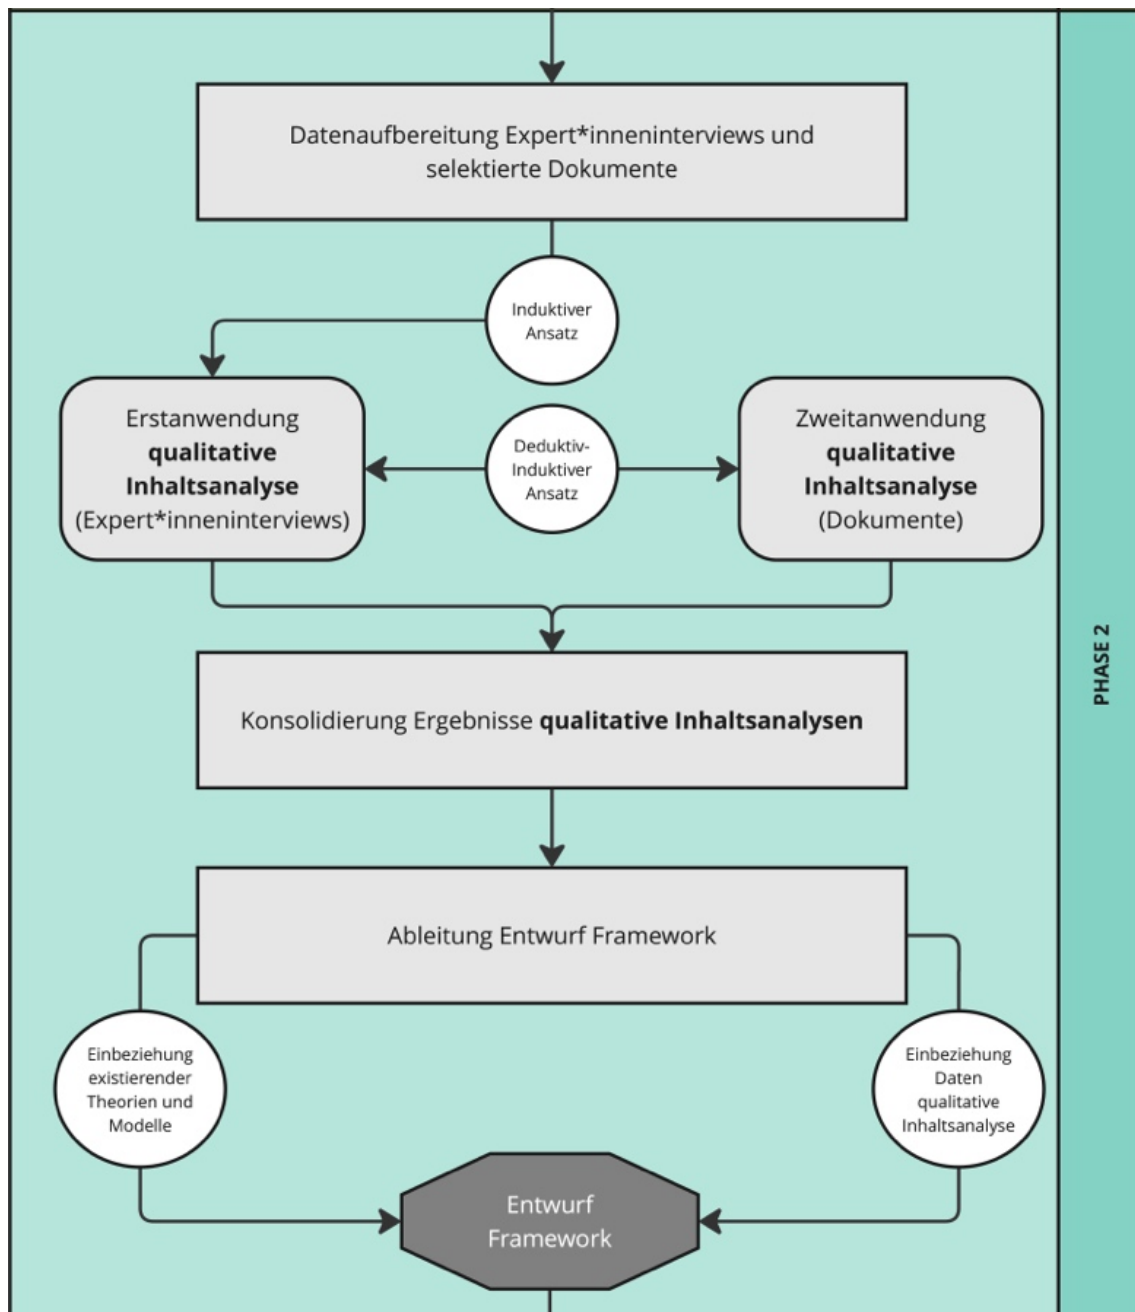


Abbildung 4: Phase 2 des Forschungsprozesses

Quelle: Eigene Darstellung

Abschließend dient die Framework Analysis der systematischen Validierung und Finalisierung des Implementierungsframeworks auf Basis von Expert*innenfeedback (Abbildung 5, Phase 3).

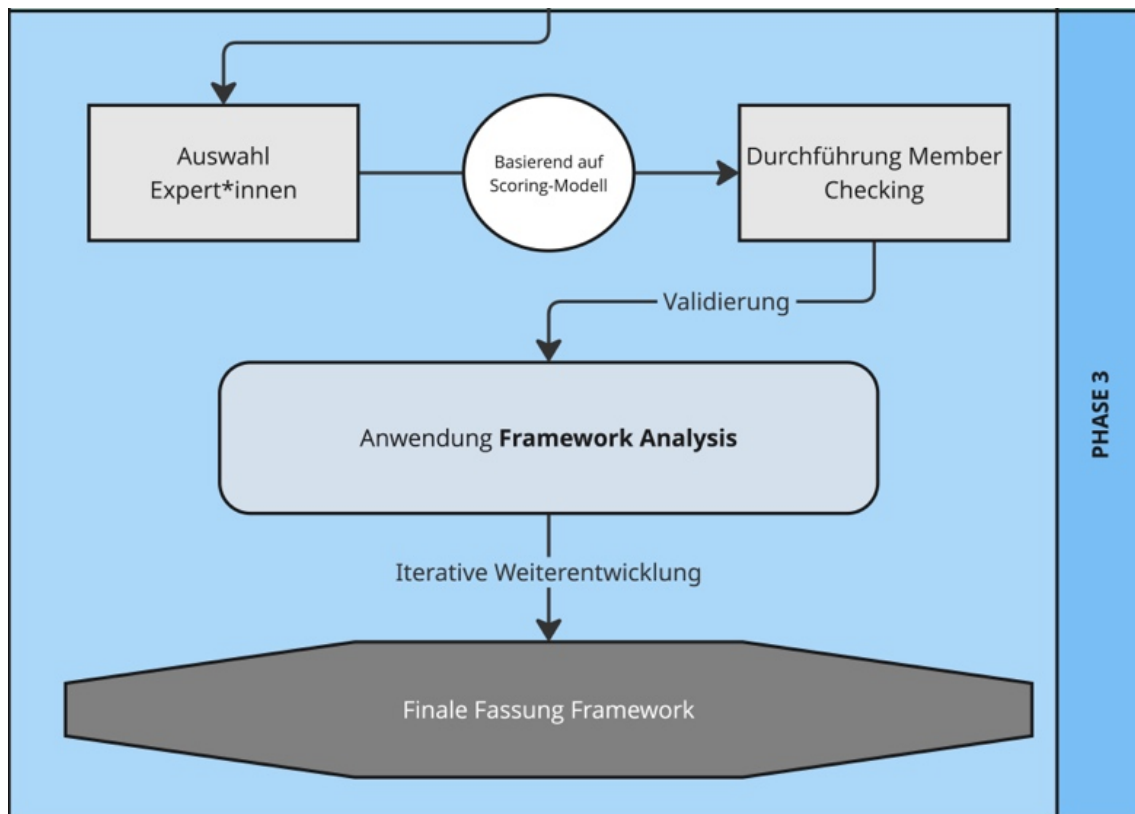


Abbildung 5: Phase 3 des Forschungsprozesses

Quelle: Eigene Darstellung

Als zentrales Prinzip der Qualitätssicherung wird die methodische Triangulation angewendet, welche die Validität durch die Konvergenz diverser Datenquellen und Analyseverfahren erhöht (Valencia, 2022). Diesbezüglich finden Expert*inneninterviews, Dokumentenanalysen und Validierungsgespräche als komplementäre Erhebungsformen Anwendung. Eine solche methodische Verschränkung gewährleistet die wissenschaftliche Rigorosität und praktische Anwendbarkeit des zu entwickelnden Implementierungsframeworks.

Nachdem die übergeordnete Systematik des Forschungsdesigns und dessen Verankerung im pragmatistischen Paradigma dargelegt wurde, folgt nun die detaillierte Beschreibung der einzelnen Phasen. Der Forschungsprozess beginnt mit der ersten Phase, die sich der Rekrutierung der Expert*innen und der Sammlung der primären Daten widmet. Das nachfolgende Kapitel 4.2.1 erläutert hierfür die zugrundeliegende Sampling-Strategie.

4.2 Phase 1: Rekrutierung und Datensammlung

4.2.1 Sampling-Strategie

4.2.1.1 Begründung zur Purposive-Sampling-Methode

Das Verfahren zur Auswahl geeigneter Expert*innen stellt einen zentralen Aspekt der methodischen Qualität dar. Im Zuge dieser Forschungsarbeit erfolgte die Stichprobenauswahl mittels Purposive Sampling, einer gezielten Auswahlstrategie, die insbesondere in der qualitativen Forschung Anwendung findet (Creswell & Plano Clark, 2018). Diese ist mit der pragmatistischen Erkenntnistheorie vereinbar, da sie eine flexible und problemorientierte Auswahl von Expert*innen ermöglicht, die über spezifisches Wissen und praktische Erfahrung zum Forschungsgegenstand verfügen (Feilzer, 2010; Teddlie & Yu, 2007).

Die Entscheidung für ein Purposive Sampling basiert auf der Zielsetzung, ein möglichst breites und zugleich tiefgehendes Verständnis über Implementierungsprozesse zu erlangen. Dabei gewährleistet die gezielte Auswahl von Expert*innen, dass sowohl Perspektiven aus verschiedenen Branchen als auch unterschiedliche Unternehmensgrößen und Funktionsbereiche abgedeckt werden. Insbesondere vor dem Hintergrund der Heterogenität des deutschen Mittelstands und der Vielschichtigkeit generativer KI-Anwendungen ist dies von zentraler Bedeutung. Durch diese Vorgehensweise wurden Personen einbezogen, die maßgeblich an der Einführung und Steuerung von generativer KI beteiligt sind, sodass die Praxisrelevanz der gewonnenen Erkenntnisse sichergestellt ist. Die praktische Umsetzung des Purposive Sampling erfolgte durch die Identifikation potenzieller Expert*innen anhand vordefinierter Auswahlkriterien. Bevor diese jedoch erläutert werden, erfolgt im nachfolgenden Kapitel eine Definition sowie Abgrenzung der Zielpopulation.

4.2.1.2 Definition und Abgrenzung der Zielpopulation

Für die Forschungsarbeit wurde eine Zielpopulation festgelegt, die alle Personen umfasst, die unmittelbar am Implementierungsprozess generativer KI in einem deutschen Unternehmen partizipieren. Der Fokus lag nicht primär auf der formalen Größe (Umsatz oder Anzahl der Mitarbeitenden) eines Unternehmens. Berücksichtigt wurden Betriebe mit Sitz in Deutschland, die sich gegenwärtig im Implementierungsprozess befinden oder diesen kürzlich abgeschlossen haben. Dabei wurden verschiedene Implementierungsstadien einbezogen, die von der initialen Planung über die Pilotierung bis hin zum produktiven Einsatz reichten.

Die Zielpopulation setzt sich insbesondere aus Fach- und Führungskräften zusammen, die aktiv an der Konzeption, Steuerung oder operativen Umsetzung beteiligt sind. Darüber hinaus wurden externe Berater*innen, Implementierungspartner*innen und Agenturen einbezogen, sofern sie deutsche KMU bei der Einführung generativer KI begleitet und entsprechende Projekterfahrung vorweisen konnten. Ein zusätzlicher Aspekt war die Berücksichtigung unterschiedlicher Branchen, wie beispielsweise Industrie, Dienstleistung und Handel, zur Gewährleistung vielfältiger Anwendungsfälle und zur Betrachtung branchenspezifischer Rahmenbedingungen.

4.2.1.3 Bestimmung der Sampling-Kriterien

Die Festlegung der Ein- und Ausschlusskriterien erfolgte entlang der Zielsetzung, die tatsächlichen Erfahrungen und Perspektiven im Implementierungsprozess systematisch zu erfassen. Beginnend mit den Einschlusskriterien, wurden ausschließlich Unternehmen berücksichtigt, die ihren Sitz in Deutschland haben und sich gegenwärtig im Implementierungsprozess befinden oder diesen kürzlich abgeschlossen haben. In die Untersuchung eingeschlossen wurden Fach- und Führungskräfte, die über strategische oder operative Verantwortung für die Einführung generativer KI verfügen. Die konkrete Zuordnung dieser Personen zu einer bestimmten Abteilung ist für die Untersuchung von untergeordneter Bedeutung. Externe Berater*innen, Agenturen und Technologiepartner*innen wurden einbezogen, sofern sie nachweislich praktische Projekterfahrung in deutschen Unternehmen vorweisen konnten.

Gegenteilig wurden Unternehmen ausgeschlossen, die keine aktiven Implementierungsprojekte vorweisen konnten. Ebenso wurden Personen exkludiert, die nicht unmittelbar am Implementierungsprozess partizipieren (z.B. Praktikant*innen) oder rein administrative Rollen innehaben. Des Weiteren wurden Berater*innen sowie Implementierungspartner*innen ohne nachweisliche Erfahrung im deutschen Unternehmenskontext (z.B. mittels Track-Records) sowie Organisationen mit Hauptsitz außerhalb Deutschlands ausgeschlossen. Letztlich diente die Erfassung der Unternehmensgröße lediglich der Kontextualisierung und stellt kein Ausschlusskriterium dar.

Die Anwendung der vorgestellten Kriterien führte zu einer Heterogenität der Stichprobe, die eine differenzierte Analyse der Implementierungsprozesse gewährleistete sowie die Übertragbarkeit der Ergebnisse auf verschiedene Unternehmens- und Anwendungskontexte erhöhte. Nachdem die Ein- und Ausschlusskriterien ausreichend dargelegt wurden, beschreibt das folgende Kapitel das Scoring-Modell zur Bewertung der Expert*innen.

4.2.2 Scoring-Modell zur Expertisebewertung und Auswahl von Expert*innen

4.2.2.1 Ableitung des Scoring-Modells zur Expertisebewertung

Die Auswahl qualifizierter Expert*innen stellt eine zentrale Prämisse für die Qualität der Forschung dar, insbesondere im Kontext von Expert*inneninterviews, bei denen die Ergebnisse maßgeblich von der fachlichen Expertise der Befragten beeinflusst werden. Demnach orientieren sich die Definition der Bewertungskriterien, die Gewichtung, Skalierung und Schwellenwertfestlegung an etablierten Verfahren der qualitativen Forschung. Insbesondere finden die Nutzwertanalyse (Zangemeister, 2014), das Scoring-Verfahren von Spencer und Spencer (1993) sowie die gewichtete Matrix (Kühnapfel, 2021) Anwendung. Der hier beschriebene Ansatz ist darauf ausgerichtet, eine systematische, transparente und wissenschaftlich fundierte Bewertung zu gewährleisten, die auf objektiven und nachvollziehbaren Kriterien basiert.

4.2.2.2 Entwicklung und Definition der Bewertungskriterien

Die Bewertungskriterien orientieren sich am Modell von Spencer und Spencer (1993), das Kompetenzen in Fach-, Methoden- und Sozialkompetenz differenziert. Dabei umfasst Fachkompetenz domänenspezifisches Wissen sowie praxisbezogene Erfahrung, wohingegen Methodenkompetenz die Anwendung analytischer Verfahren bezeichnet. Fortfolgend umfasst die Sozialkompetenz kommunikative Fähigkeiten sowie Netzwerkbildung. Letztlich wird die strategische Kompetenz gemäß Krüger (2014) ergänzend berücksichtigt, die sich auf die Initiierung und Steuerung von Veränderungsprozessen bezieht. Auf dieser Grundlage wurden die Kriterien für das Scoring-Modell entsprechend den Anforderungen des Forschungsvorhabens abgeleitet und in Tabelle 8 charakterisiert.

Tabelle 8: Bewertungskriterien für das Scoring-Modell zur Expert*innenauswahl

Kompetenzdimension	Bewertungskriterium	Charakterisierung / Indikatoren
Fachkompetenz	Projekterfahrung	Praktische Anwendung und Integration der Technologie; Menge und Qualität der Berufserfahrung
	Publikationen & Vorträge	Wissenschaftliche und praktische Auseinandersetzung mit dem Themenbereich
	Zertifizierungen & Fortbildungen	Nachweis der kontinuierlichen Weiterentwicklung und fachlichen Spezialisierung
Sozialkompetenz	Netzwerk & Reputation	Reichweite auf Social-Media-Kanälen, Mundpropaganda, Verankerung in der Fachcommunity und interdisziplinärer Austausch
Strategische Kompetenz	Führungserfahrung	Übernahme strategischer Verantwortung sowie Erfahrung in der Initiierung und Steuerung von Veränderungsprozessen

Quelle: Eigene Darstellung in Anlehnung an Spencer und Spencer (1993) und Krüger (2014)

Als zentrales Kriterium galt die Projekterfahrung der Expert*innen, da sie die praktische Anwendung und Integration der Technologie im Unternehmen widerspiegelt. Als Indikator wurde die Menge und Qualität der in einem Beruf erworbenen Erfahrungen für die Kontinuität und die Tiefe betrachtet. Neben der Projekterfahrung offenbarte eine detaillierte Analyse veröffentlichter Publikationen und gehaltener Vorträge die wissenschaftliche und praktische Auseinandersetzung der Expert*innen mit dem Themenbereich. Ein weiteres Kriterium stellte die Netzwerk- und Repräsentationsstruktur im Fachgebiet dar. Diese manifestiert sich sowohl in der Reichweite auf Social-Media-Kanälen als auch durch Mundpropaganda und reflektiert die Verankerung in der Fachcommunity sowie den interdisziplinären Austausch. Der Kriterienkatalog wurde durch die Aspekte Führungserfahrung, Zertifizierungen und Fortbildungen ergänzt, da sie die strategische Verantwortung und kontinuierliche Weiterentwicklung abbilden.

4.2.2.3 Gewichtung der Bewertungskriterien

Die Gewichtung der Bewertungskriterien erfolgte nach ihrer Relevanz für die Forschungsfragen. Aus methodischer Perspektive wurde die gewichtete Matrix als Analyseinstrument ausgewählt, da sie eine direkte Zuweisung von Gewichtungsfaktoren zu allen Kriterien ermöglicht und subjektive Verzerrungen minimiert (Kühnapfel, 2021). Im Gegensatz zur Paarvergleichsmethode, die bei einer zunehmenden Anzahl an Kriterien mit zunehmendem Aufwand und einer methodischen Unschärfe konfrontiert ist (Döring, 2023), gewährleistet die

gewichtete Matrix eine konsistente und transparente Bewertung und kann der Tabelle 9 entnommen werden.

Tabelle 9: Gewichtung der Bewertungskriterien im Scoring-Modell

Bewertungskriterium	Gewichtung
Projekterfahrung	35 %
Berufserfahrung	25 %
Publikationen und Vorträge	15 %
Netzwerk und Reichweite	10 %
Führungserfahrung	10 %
Zertifizierungen und Fortbildungen	5 %
Gesamt	100 %

Quelle: Eigene Darstellung

In der praktischen Umsetzung des Scoring-Modells wurde der „Projekterfahrung“ eine Gewichtung von 35 % zugewiesen, da sie die unmittelbare Anwendungskompetenz widerspiegelt. „Berufserfahrung“ wurde mit 25 % berücksichtigt, da sie die fachliche Kontinuität und den Umfang der Auseinandersetzung mit dem Forschungsfeld abbildet. Die Bewertung von „Publikationen und Vorträgen“ erfolgte mit einem Faktor von 15 %, um die wissenschaftliche Partizipation adäquat zu erfassen. Die Kriterien „Netzwerk und Reichweite“ sowie „Führungserfahrung“ flossen jeweils mit 10 % in die Bewertung ein, da sie die Verankerung in der Fachcommunity und die Leitungskompetenz dokumentieren. „Zertifizierungen und Fortbildungen“ wurden mit einer Gewichtung von 5 % berücksichtigt, um die Aktualität des Fachwissens abzubilden.

4.2.2.4 Skalierung der Bewertungskriterien

Die Bewertung der Expertise erfolgte durch den Forscher selbst auf einer sechsstufigen Skala, wodurch eine differenzierte und nachvollziehbare Einschätzung ermöglicht wurde (Döring, 2023; Kühnapfel, 2021). Die Entscheidung zu einer geraden Skala birgt den Vorteil, dass sie Neutralpunkte vermeidet und die Aussagekraft der Bewertungen erhöht, wodurch eine klare Positionierung gefordert sowie Bewertungsverzerrungen durch Zentralitätseffekte minimiert werden (Kühnapfel, 2021). Die Skala wurde einheitlich auf alle Kriterien angewendet, wobei jeder Wert innerhalb von Tabelle 10 eine klar definierte Ausprägung abbildet.

Tabelle 10: Sechsstufige Skala zur Bewertung der Expertise

Erläuterung Skalenwert	Wert
nicht vorhanden	1
sehr geringe Ausprägung	2
geringe Ausprägung	3
mittlere Ausprägung	4
hohe Ausprägung	5
sehr hohe Ausprägung	6

Quelle: Eigene Darstellung

Ein Wert von 1 indiziert das Fehlen jeglicher Projekterfahrung, während ein Wert von 6 die Leitung von mehr als fünf Projekten anzeigt. Die Berufserfahrung wird anhand der Jahre einschlägiger Tätigkeit bewertet. Sowohl Publikationen und Vorträge als auch Zertifizierungen und Fortbildungen werden nach ihrer Anzahl und Relevanz beurteilt. Das aufgebaute Netzwerk sowie die Reichweite von Beiträgen werden maßgeblich anhand der Aktivität und Sichtbarkeit in sozialen Netzwerken gewertet. Für die Erfassung der Führungserfahrung sind schließlich die Größe und Verantwortung der geleiteten Teams wesentliche Bewertungsmaßstäbe.

4.2.2.5 Festlegung der Schwellenwerte und Interpretation

Einen zentralen Bestandteil des Scoring-Modells bildete die Festlegung klar definierter Schwellenwerte. Diese erfolgte gemäß den Prinzipien der Nutzwertanalyse durch eine strukturierte Kombination und gewichtete Bewertung der festgelegten Kriterien (Zangemeister, 2014). Eine solche Vorgehensweise ermöglicht die Einordnung der Gesamtpunktzahlen in differenzierte Kompetenzniveaus und schafft eine transparente Entscheidungsgrundlage für die Auswahl geeigneter Expert*innen (Kühnapfel, 2021). Ein in diesem Zusammenhang wesentlicher Aspekt – neben dem Kompensations- und Transparenzprinzip – ist das sogenannte Dominanzprinzip, nach dem besonders maßgebliche Kriterien wie die Projekterfahrung die Gesamtbewertung dominieren. Gemäß dem Kompensationsprinzip können wiederum Schwächen in weniger gewichteten Kriterien durch Stärken in dominierenden Bereichen kompensiert werden (Kühnapfel, 2021; Zangemeister, 2014). Zusätzlich gewährleistet das Transparenzprinzip, dass die Bewertungslogik nachvollziehbar dokumentiert ist. Die Expertisekategorien wurden innerhalb von Tabelle 11 wie folgt definiert.

Tabelle 11: Definition der Expertisekategorien und Schwellenwerte

Expertisekategorie	Gesamtpunktzahl	Interpretation und Konsequenz für die Auswahl
Exzellente Expertise	5,0 – 6,0	Umfassende Projekterfahrung, ausgeprägte Führungskompetenzen und hohe Vernetzung
Hohe Expertise	3,5 – 4,9	Ausgeprägte Projekterfahrung und fundiertes Fachwissen
Mittelmäßige Expertise	2,5 – 3,4	Eingeschränkte Eignung; Kompensation durch ergänzende Qualifikationen erforderlich
Geringe Expertise	< 2,5	Deutliche Defizite; führt zum Ausschluss aus der Stichprobe

Quelle: Eigene Darstellung in Anlehnung an Kühnapfel (2021) und Zangemeister (2014)

Eine Gesamtpunktzahl von 5,0 bis 6,0 repräsentiert den höchsten erreichbaren Grad der Expertise („Exzellente Expertise“), der mit einer umfassenden Projekterfahrung, ausgeprägten Führungskompetenzen und einer hohen Vernetzung in sozialen Netzwerken einhergeht. Eine Punktzahl von 3,5 bis 4,9 wurde als „Hohe Expertise“ gewertet und kennzeichnet demnach ausgeprägte Projekterfahrung sowie fundiertes Fachwissen. Personen, deren Werte zwischen 2,5 und 3,4 liegen, wurden mit „Mittelmäßige Expertise“ eingestuft. Sie weisen eine eingeschränkte Eignung auf, für deren Kompensation der Nachweis ergänzender Qualifikationen erforderlich ist. Werte, die kleiner als 2,5 sind, werden als „Geringe Expertise“ klassifiziert. Diese Kennzahl signalisiert deutliche Defizite und führte zum Ausschluss aus der Stichprobe.

Mit der Festlegung der Expertisekategorien und der dazugehörigen Schwellenwerte ist das Scoring-Modell zur Anwendung vollständig operationalisiert. Aufbauend auf diesem Bewertungsrahmen wird im folgenden Kapitel die konkrete Rekrutierungsstrategie dargelegt, mit der die Expert*innen systematisch für die Untersuchung identifiziert wurden.

4.2.3 Rekrutierungsstrategie

4.2.3.1 Zielsetzung und methodische Einordnung

Die in diesem Forschungsdesign eingesetzte Rekrutierungsstrategie steht in engem Zusammenhang mit der pragmatistischen Erkenntnistheorie. Ihr Ziel besteht in der systematischen Gewinnung einer heterogenen und zugleich fachlich qualifizierten Gruppe von Expert*innen, die über einschlägige Erfahrungen mit der Implementierung von generativer KI im Unternehmenskontext verfügen. Die Selektion der Teilnehmenden erfolgte auf Basis der im Scoring-Modell definierten Kriterien, mit dem Ziel, eine hohe Praxisrelevanz und Anwendungsnähe der Untersuchungsergebnisse zu gewährleisten. Die Verbindung von gezielter

Identifikation, objektiver Bewertung und transparenter Dokumentation trug zur Qualität und Vergleichbarkeit der erhobenen Daten bei und ermöglicht eine methodische Nachvollziehbarkeit des gesamten Auswahlprozesses.

4.2.3.2 Rekrutierungskanäle und praktische Umsetzung

Als primärer Rekrutierungskanal wurde das soziale Berufsnetzwerk LinkedIn genutzt und 334 Personen kontaktiert. Die Plattform fungierte als Instrument zur gezielten Identifikation von Expert*innen auf dem Gebiet der generativen KI. Die Identifikation relevanter Personen erfolgte insbesondere durch die Analyse der Follower-Struktur und der Beiträge führender Meinungsführer*innen. Zudem wurden spezifische Such- und Filterkriterien angewendet, die sich auf die berufliche Ausrichtung, die Position im Unternehmen und einschlägige Interessen beziehen. Hinsichtlich der initialen Kontaktaufnahme wurde eine personalisierte Kommunikation auf Basis der jeweiligen Profilinformationen vorgenommen. Vorzugsweise erfolgte der Erstkontakt in persönlicher Form auf Fachveranstaltungen oder über die Nachrichtenfunktion von LinkedIn. Die nachfolgende Abbildung 6 dokumentiert die Ergebnisse des Rekrutierungsprozesses und schlüsselt die Anzahl der Kontaktanfragen sowie die daraus resultierende Rücklaufquote auf.

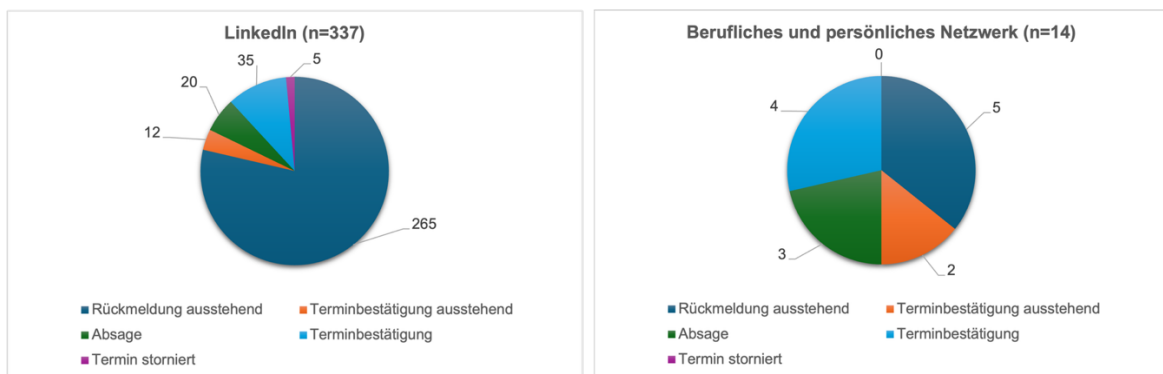


Abbildung 6: Ergebnisse des Rekrutierungsprozesses

Quelle: Eigene Darstellung

Als sekundärer Rekrutierungskanal wurde das berufliche und persönliche Netzwerk des Autors sowie Arbeitskreise, Workshops und Branchenevents genutzt, um potenzielle Teilnehmende auch im direkten persönlichen Austausch zu gewinnen. Gleichwohl wurde das Schneeballprinzip in Form von Mundpropaganda sowie Empfehlung durch die Expert*innen genutzt und schließlich 14 Personen kontaktiert. Im Rahmen des Rekrutierungsprozesses wurde sowohl im primären als auch im sekundären Rekrutierungskanal besonderer Wert auf

eine personalisierte Kommunikation gelegt. Das Ziel bestand darin, die Rücklaufquote und die Motivation der Expert*innen zur Teilnahme zu steigern.

4.2.3.3 Stichprobengröße und -zusammensetzung

Die Anzahl der durchgeführten Expert*inneninterviews wurde nicht vorab festgelegt, sondern orientierte sich am Prinzip der theoretischen Sättigung (Glaser et al., 2010; Kruse, 2015). Demzufolge wurde die Datenerhebung so lange fortgeführt, bis in den Interviews keine neuen relevanten Themen, Muster oder Kategorien mehr identifiziert werden konnten. Dieses Vorgehen entspricht den methodologischen Standards der qualitativen Sozialforschung und gewährleistet, dass die empirische Basis sowohl inhaltlich repräsentativ als auch theoretisch fundiert ist (Häder, 2019). Die letztlich erreichte Stichprobengröße von 39 Expert*innen ist somit als Ergebnis des Forschungsprozesses zu verstehen und nicht als vorab definierte Zielgröße.

Die Stichprobe setzt sich aus 22 Fach- und Führungskräften sowie 17 externen Berater*innen und Technologiepartner*innen zusammen. Dadurch werden sowohl unternehmensinterne als auch externe Perspektiven im Zuge des Implementierungsprozesses berücksichtigt. Die Teilnehmenden repräsentieren diverse Branchen, darunter Industrie (11 Personen), Handel (8 Personen), Dienstleistungen (10 Personen), E-Commerce (3 Personen), Energieversorgung (4 Personen) und Wissenschaft (3 Personen). Hinsichtlich der Unternehmensgröße reicht das Spektrum von Startups über klassische KMU bis hin zu Großunternehmen. Letztlich verfügen die Expert*innen über ausgewiesene Erfahrung in der strategischen Steuerung, operativen Umsetzung und Beratung von KI-Anwendungen.

Die Heterogenität der zusammengesetzten Stichprobe stellt somit das Ergebnis eines systematischen Auswahlprozesses dar, der eine differenzierte Analyse der Implementierungsprozesse gewährleistet und die Übertragbarkeit der Ergebnisse auf verschiedene Unternehmens- und Anwendungskontexte erhöht. Um die Perspektiven dieser Expert*innengruppe systematisch zu erheben, widmet sich das nachfolgende Kapitel dem zentralen Erhebungsinstrument und erläutert dessen Konzeption und Aufbau.

4.2.4 Expert*inneninterviews

4.2.4.1 Entwicklung des halbstrukturierten Interviewleitfadens

Die Entwicklung des Interviewleitfadens erfolgte in einem systematischen und mehrstufigen Prozess, der sich konsequent an den Prinzipien der theoretischen Fundierung und methodischen Nachvollziehbarkeit orientiert (Helfferich, 2009; Kuckartz, 2018). Ausgangspunkt der Untersuchung war die LF sowie die EF, die als Basis für die inhaltliche Strukturierung und Priorisierung der Interviewfragen fungierten.

Grundsätzlich wurde der Interviewleitfaden in drei Abschnitte unterteilt: Einleitung, Hauptteil und Abschluss. In der Einleitung wurde die Zielsetzung des Interviews und der Ablauf dargelegt, um eine vertrauensvolle Gesprächsatmosphäre zu schaffen. Wiederum gliedert sich der Hauptteil in die fünf Themenblöcke, wobei Haupt- und Vertiefungsfragen eine flexible und zugleich strukturierte Erhebung ermöglichen. Der Abschlussteil dient der Klärung offener Punkte sowie der Abfrage der Bereitschaft zur weiteren Mitwirkung im Forschungsprozess. Die Struktur der Leitfragen wurde so konzipiert, dass sie sowohl Hauptfragen als auch vertiefende Nachfragen umfasst. Dies dient einerseits der Sicherstellung der Vergleichbarkeit zwischen den Interviews und andererseits der Schaffung von Raum für individuelle Erfahrungen und Kontextinformationen.

Die Ableitung der Themenblöcke erfolgte deduktiv. Demzufolge wurden aus dem Forschungsstand der Kapitel 2.2, 2.3, 2.4 und 2.5 sowie den Kern- und Kontexttheorien (Kapitel 3.3.1 und 3.3.2) die folgenden fünf zentralen Themenblöcke abgeleitet, um eine umfassende und theoriegeleitete Datenerfassung zu gewährleisten: (1) Verlauf des Implementierungsprozesses, (2) abgeleitete Implementierungsstrategie (KI-Strategie), (3) Anwendung von Basistechnologien (KI-Technologien), (4) Ableitung von Bewertungskriterien zur Erfolgsmessung sowie (5) zukünftige Projektvorhaben (KI-Roadmap). Ergänzend dazu wurde eine Priorisierung in zwei Stufen vorgenommen. Themenblöcke, die einen unmittelbaren Bezug zur Beantwortung der Forschungsfragen aufwiesen, wurden als „Priorität 1“ eingestuft. Ergänzende Themenblöcke dienten der Kontextualisierung und Vertiefung und wurden mit „Priorität 2“ gekennzeichnet.

Die Auswahl der theoretischen Modelle zur Fundierung der einzelnen Themenblöcke erfolgte selektiv, um die spezifischen Herausforderungen und Rahmenbedingungen der Implementierung generativer KI adäquat abzubilden. Gemäß der Diffusion-of-Innovations-Theory von Rogers (2003) wird die Implementierung neuer Technologien als ein komplexer

und mehrstufiger sozialer Prozess beschrieben. Demnach ermöglicht die Theorie die Identifizierung typischer Adoptionsmuster sowie die Analyse von Barrieren und Erfolgsfaktoren, die die Annahme neuer Technologien im Implementierungsprozess beeinflussen. Das Drei-Phasen-Modell von Lewin (1947) bietet hierzu einen ergänzenden Rahmen zur Analyse organisationaler Veränderungsprozesse, während das TOE-Framework nach Tornatzky & Fleischer (1990) eine systematische Erfassung technologischer, organisationaler und umweltbezogener Einflussfaktoren ermöglicht. Für die strategische Dimension wurden der Resource-Based View nach Barney et al. (2001) und die Dynamic-Capabilities-Theory nach Teece et al. (1997) gewählt. Beide Konzepte betonen in unterschiedlicher Weise die Bedeutung von Ressourcen, Kompetenzen und Anpassungsfähigkeit für nachhaltige Wettbewerbsvorteile. Die Themenblöcke „Bewertungskriterien“ und „KI-Roadmap“ basieren schließlich auf dem Ansatz des Performance Measurement nach Kaplan & Norton (1996) zur Etablierung valider Bewertungsverfahren und -maßstäbe im Rahmen der Erfolgsmessung. Schließlich wurde die Erstellung von zwei unterschiedlichen Versionen des Leitfadens realisiert, um den unterschiedlichen Perspektiven interner und externer Expert*innen Rechnung zu tragen (siehe Anhang A und B).

4.2.4.2 Durchführung Pretest und Optimierung Interviewleitfaden

Im Rahmen eines Pretests erfolgte die Erprobung des Leitfadens unter realen Bedingungen. Zu diesem Zweck wurde dieser mit drei Expert*innen aus der Unternehmenspraxis sowie zwei aus dem externen Beratungsumfeld erprobt. Die Erkenntnisse aus der Pretest-Phase legen nahe, dass insbesondere die Platzierung und die Komplexität einzelner Fragen Auswirkungen auf die Länge des Gesprächsverlaufs und die Tiefe der erhobenen Daten hatten. Schließlich wurde der Leitfaden durch die zielgerichtete Anpassung der Fragestellungen und die Berücksichtigung der Rückmeldungen der Expert*innen so konzipiert, dass sowohl die Vergleichbarkeit als auch die Kontextualisierung der Ergebnisse gewährleistet werden konnte. Zudem führte das Feedback zur spezifischen Anpassung von Themenblöcken, wobei insbesondere die Berücksichtigung der Unternehmensgröße in der Implementierungsstrategie (Themenblock 2) sowie die Ergänzung qualitativer Messbarkeitsdimensionen bei der Erfolgsmessung (Themenblock 4) überarbeitet wurden. Darüber hinaus wurde der Gesprächseinstieg verändert, einzelne Fragen zur besseren Nachvollziehbarkeit umstrukturiert und komplexe Fragestellungen reduziert.

Im Anschluss erfolgte eine Evaluierung und Optimierung weiterer Aspekte der Interviewdurchführung. In diesem Kontext wurden insbesondere die Reihenfolge der Fragen sowie deren Formulierungen und der Abschluss des Interviews marginal angepasst. Die vorgenommenen Modifikationen zielten darauf ab, die Verständlichkeit und Antwortbereitschaft der Expert*innen zu erhöhen sowie die Erhebung möglichst störungsfrei und effizient zu gestalten. Die finale Version des Interviewleitfadens fungierte folglich als Basis für die Datenerhebung und kann den Anhängen C und D entnommen werden.

4.2.4.3 Durchführung und Dokumentation der Expert*inneninterviews

Die Durchführung sowie Dokumentation der Expert*inneninterviews erfolgte im Rahmen eines systematisch geplanten, mehrstufigen Prozesses, der auf die Erhebung tiefgehender, praxisrelevanter Erkenntnisse abzielt. Im Folgenden werden die einzelnen Schritte detailliert beschrieben.

Die Interviews wurden unter realitätsnahen Bedingungen durchgeführt, um eine möglichst authentische Erhebung der Erfahrungen und Einschätzungen der Expert*innen zu gewährleisten. Als technisches Medium kam Microsoft Teams zum Einsatz, was eine flexible und ortsunabhängige Teilnahme ermöglichte. Die Terminierung erfolgte individuell und unter Berücksichtigung der Verfügbarkeiten der Teilnehmenden. Vor jedem Interview erhielten die Expert*innen eine schriftliche Einladung mit Informationen zum Forschungsvorhaben, den Zielen des Interviews sowie datenschutzrechtlichen Hinweisen. Die Einwilligung zur Teilnahme und zur möglichen Audioaufzeichnung wurde vor Aufzeichnungsbeginn eingeholt.

Durchgeführt wurden die Gespräche als halbstrukturierte, leitfadengestützte Interviews. Der Interviewleitfaden wurde im Vorfeld entwickelt, in einem Pretest erprobt und auf Basis von Feedback optimiert, sodass er die Vergleichbarkeit der Interviews als auch die Berücksichtigung individueller Kontextfaktoren ermöglichte. Zu Beginn jedes Interviews wurden die Zielsetzung, der Ablauf und die Vertraulichkeit der Angaben erläutert, um eine vertrauensvolle Gesprächsatmosphäre zu schaffen. Während des Gesprächs wurde darauf geachtet, offene und vertiefende Nachfragen zu stellen, um sowohl standardisierte als auch individuelle Erfahrungen und Einschätzungen zu erfassen. Die Interviews wurden vom Forscher selbst moderiert und protokolliert (s. Anhang E).

Die Dokumentation und Nachbereitung der Interviews erfolgte in mehreren aufeinanderfolgenden Schritten. Alle Teilnehmenden erteilten ihre Zustimmung, sodass sämtliche Interviews vollständig aufgezeichnet werden konnten. Die anschließende Transkription wurde auf Basis einer Kombination von Transkriptionsregeln nach Kuckartz (2018) sowie Dresing & Pehl (2018) durchgeführt, um eine einheitliche und analytisch verwertbare Datenbasis zu gewährleisten. Zusätzlich wurden während der Interviews stichpunktartige Protokolle angefertigt, in denen zentrale Aussagen, nonverbale Hinweise und spontane Eindrücke festgehalten wurden. Diese Protokolle dienen als ergänzende Quelle zur Kontextualisierung der Transkripte. Im Rahmen der Transkription und Dokumentation wurden sämtliche potenziell identifizierenden Daten konsequent anonymisiert. Dies umfasste nicht nur die Namen der Expert*innen und ihrer Unternehmen, sondern auch spezifische Produkt-, Projekt- oder Abteilungsbezeichnungen, die Rückschlüsse auf die Herkunft der Daten zugelassen hätten. Die Transkripte, Protokolle und Audioaufnahmen wurden systematisch archiviert und in einer Datenbank strukturiert abgelegt. Die Verwaltung und Analyse der Daten erfolgte mit der Software MAXQDA, wodurch eine transparente Nachverfolgung aller Kodierungen und Analysewege sichergestellt werden konnte.

Nachdem die primäre Datenerhebung durch die Expert*inneninterviews erläutert wurde, wird die empirische Basis durch eine ergänzende Dokumentenanalyse erweitert. Dieser Schritt diente dazu, die durch die Interviews gewonnenen Erkenntnisse zu kontextualisieren und um zusätzliche, authentische Perspektiven aus der Praxis anzureichern. Das folgende Kapitel erläutert die methodischen Grundlagen dieser zweiten Datenquelle.

4.2.5 Ergänzende Dokumentenanalyse

4.2.5.1 Entwicklung und Definition der Ein- und Ausschlusskriterien

Für die vorliegende Untersuchung wurde das Medienformat Podcast als ergänzende Datenquelle ausgewählt, da diese authentische, kontextbezogene und häufig spontane Erfahrungsberichte, Einschätzungen und Reflexionen von Expert*innen aufzeichnen. Im Vergleich zu klassischen Dokumentenformaten wie Projektberichten, Whitepapers oder Branchenstudien bieten Podcasts eine größere inhaltliche Tiefe und Vielschichtigkeit, da sie unmittelbare und ungefilterte Einblicke in individuelle und kollektive Handlungs- und Deutungsmuster erlauben (Bowen, 2009; Flick, 2016). Im Verlauf der Rekrutierung stellte sich heraus, dass eine Gruppe von Expert*innen für Interviews nicht verfügbar war oder eine Teilnahme ablehnte.

Dennoch konnten die Perspektiven und Einschätzungen dieser Personen in den Datenbestand einfließen, da sie regelmäßig als Gäste in Podcasts auftraten oder eigene Podcast-Formate besitzen. Mayring (2022) und Kuckartz (2018) betonen in diesem Zusammenhang, dass Medienformate mit hoher Authentizität und Aktualität insbesondere in dynamischen Forschungsfeldern einen substantiellen Beitrag zur Validität qualitativer Analysen leisten können. Die Auswahl der Podcasts erfolgte anhand klar operationalisierter Ein- und Ausschlusskriterien, die Tabelle 12 entnommen werden können.

Tabelle 12: Ein- und Ausschlusskriterien für die Auswahl der Podcasts

Kriterium	Beschreibung und Operationalisierung
Einschlusskriterien	
<i>Reputation</i>	Hohe Reputation der Hosts und/oder Gäste, nachweisbar durch fachliche Expertise, Branchenbekanntheit oder einschlägige Publikationen.
<i>Thematische Relevanz</i>	Inhaltlicher Fokus auf die Implementierung generativer KI im Unternehmenskontext.
<i>Aktualität</i>	Veröffentlichungszeitraum zwischen 2023 und 2025.
<i>Inhaltliche Tiefe</i>	Adäquate Anzahl an Folgen, die eine inhaltliche Kontinuität und tiefgehende Auseinandersetzung mit dem Thema gewährleisten.
<i>Verfügbarkeit</i>	Zugänglichkeit auf etablierten Plattformen (z. B. Spotify, Apple Podcasts, podcast.de, podimo).
Ausschlusskriterien	
<i>Fehlende Transparenz</i>	Die Urheberschaft des Podcasts kann nicht eindeutig geklärt werden.
<i>Mangelnde Fachlichkeit</i>	Der Inhalt weist keine ausreichende fachliche Fundierung auf oder ist oberflächlich.
<i>Veralteter Inhalt</i>	Der Podcast wird nicht mehr aktualisiert oder die Inhalte sind nicht mehr auf dem neuesten Stand.
<i>Werblicher Charakter</i>	Der Podcast dient primär und in eindeutiger Weise werblichen Zwecken.

Quelle: Eigene Darstellung in Anlehnung an Bowen (2009), Kuckartz (2018) und Mayring (2022)

Eingeschlossen wurden Podcasts, die folgende Kriterien erfüllten: (1) hohe Reputation der Hosts und/oder Gäste, nachweisbar durch fachliche Expertise, Branchenbekanntheit oder einschlägige Publikationen; (2) thematische Passgenauigkeit zum Forschungsgegenstand, insbesondere zur Implementierung generativer KI im Unternehmenskontext; (3) Aktualität, d. h. Veröffentlichung im Zeitraum 2023 bis 2025 und ein aktuelles Erscheinungsdatum der letzten Folge; (4) adäquate Anzahl an Folgen, um eine inhaltliche Tiefe und Kontinuität zu gewährleisten; (5) Verfügbarkeit auf etablierten Plattformen wie Spotify, Apple Podcasts,

podcast.de oder podimo. Ausgeschlossen wurden Podcasts, deren Urheberschaft nicht eindeutig geklärt werden konnte, die keine ausreichende fachliche Fundierung aufwiesen, die nicht auf dem aktuellen Stand waren oder die in eindeutiger Weise werblichen Zwecken dienten. Die konsequente Anwendung dieser Kriterien gewährleistete eine hohe inhaltliche Qualität und minimierte das Risiko von Verzerrungen durch minderwertige Quellen (Bowen, 2009; Mayring, 2022).

4.2.5.2 Systematische Podcastrecherche

Die Identifikation und Auswahl relevanter Podcasts erfolgte im Rahmen einer systematischen Recherche. Ausgangspunkt der Recherche waren zunächst jene Expert*innen, die für die Teilnahme an den Expert*inneninterviews nicht zur Verfügung standen oder eine Teilnahme abgelehnt hatten, jedoch als Gäste in Podcasts auftraten oder selbst Podcasts produzierten. In der Folge wurden sowohl Empfehlungen und Hinweise aus den Expert*inneninterviews als auch informelle Hinweise aus Off-the-Record-Gesprächen berücksichtigt. Im Anschluss wurde das Schneeballprinzip angewandt, indem die Empfehlungen von Gästen und Hosts aus den bereits identifizierten Podcasts berücksichtigt worden sind. Die Recherche wurde auf den führenden Podcast-Datenbanken Spotify, Apple Podcasts, podcast.de und podimo durchgeführt. Zusätzlich wurden spezifische Suchbegriffe innerhalb der Suchfunktionen genannter Datenbanken verwendet, die sich direkt aus der Forschungsfrage ergeben. Dazu zählen „künstliche Intelligenz“, „KI“, „generative KI“, „GenAI“, „Implementierung“, „Mittelstand“ und „KMU“. Das Ergebnis dieser systematischen Recherche wird innerhalb der nachfolgenden Abbildung 7 als Flowchart visualisiert.

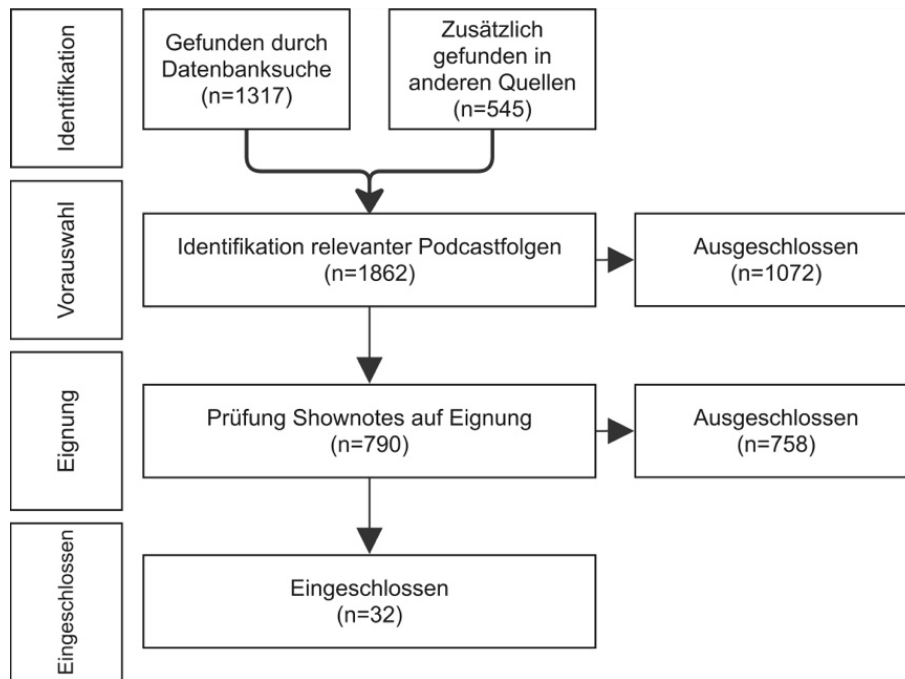


Abbildung 7: PRISMA-Flowchart ein- und ausgeschlossener Podcasts

Quelle: Eigene Darstellung

Mit der Beschreibung der systematischen Podcastrecherche ist die Darstellung der Methodik zur Datenerhebung in Forschungsphase 1 abgeschlossen. Der so gewonnene Datenkorpus bildet die Grundlage für die nun folgende zweite Forschungsphase. Diese widmet sich der Datenauswertung und der darauf basierenden Entwicklung des ersten Framework-Entwurfs.

4.3 Phase 2: Entwicklung Erstentwurf Implementierungsframeworks

4.3.1 Qualitative Inhaltsanalyse nach Kuckartz (induktiv) – Expert*inneninterviews

4.3.1.1 Datenbasis und Transkription

Als Datengrundlage dienten 39 Expert*inneninterviews, die mit Fach- und Führungskräften aus unterschiedlichen Branchen durchgeführt und anschließend transkribiert wurden. Die Gespräche hatten eine durchschnittliche Dauer von 40 bis 50 Minuten. Ergänzt wurde die Datenbasis durch die entsprechenden Interviewprotokolle je Expert*inneninterview.

Für die Transkription wurde ein hybrides Regelset entwickelt, das die analytische Präzision nach Kuckartz (2018) mit dem Fokus auf Lesbarkeit nach Dresing und Pehl (2018) verbindet. Ziel war es, einen Datenkorpus zu schaffen, der sowohl für die computergestützte Analyse in MAXQDA optimiert ist als auch eine gute Lesbarkeit für den interpretativen Arbeitsgang gewährleistet. Hierzu erfolgte eine leichte Glättung von Füllwörtern wie „äh“ oder

„ähm“. Zudem wurden Wortabbrüche und Stottern zur Steigerung der Lesbarkeit entfernt, sofern sie keine analytische Bedeutung hatten, und dialektale Färbungen wurden in Schriftsprache überführt. Die systematische Auswertbarkeit wurde schließlich durch einheitliche formale Konventionen sichergestellt, insbesondere durch die durchgängige Verwendung von Sprecher-Kürzeln und die konsequente Anonymisierung aller sensiblen Daten.

4.3.1.2 Analytisches Vorgehen zur qualitativen Inhaltsanalyse

Für die Auswertung der Expert*inneninterviews wurde die inhaltlich-strukturierende Inhaltsanalyse nach Kuckartz (2018) gewählt. Die Entscheidung für diesen spezifischen Typ der Inhaltsanalyse begründet sich unmittelbar im Forschungsziel: Es sollen nicht nur Inhalte zusammengefasst, sondern die zentralen thematischen Strukturen im Datenmaterial herausgearbeitet werden, die als Basis für die Entwicklung des Implementierungsframeworks dienen. Ferner unterstützt die Methode den explorativen Charakter der Untersuchung, indem sie hermeneutische Flexibilität für Sprünge zwischen den Analysephasen bietet und die Kombination von deduktiver sowie induktiver Kategorienbildung ermöglicht. Zur technischen Umsetzung wurde die Analysesoftware MAXQDA eingesetzt, die eine systematische Dokumentation des Analyseprozesses gewährleistet. Die nachfolgende Abbildung 8 dokumentiert das konkrete methodische Vorgehen.

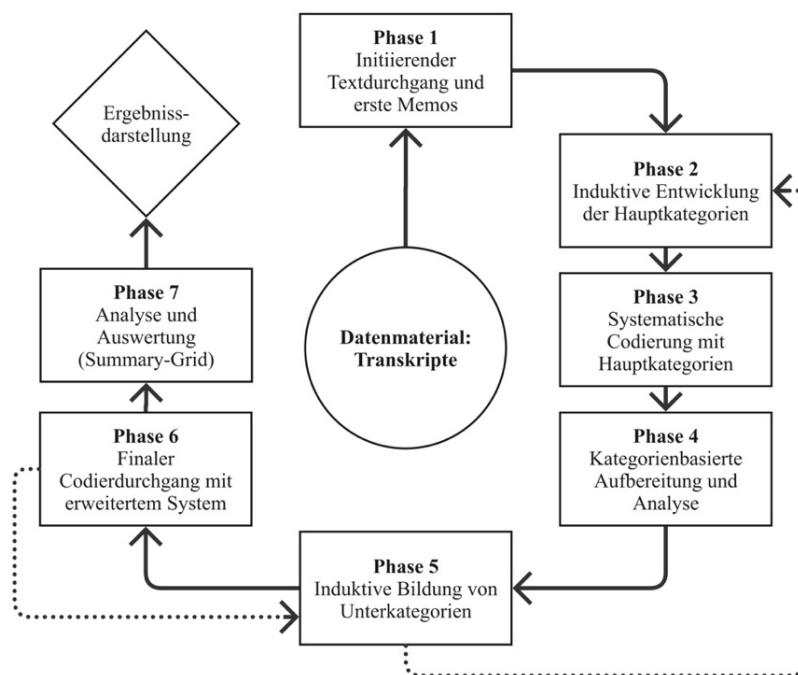


Abbildung 8: Ablaufschema der inhaltlich-strukturierenden Inhaltsanalyse

Quelle: Eigene Darstellung in Anlehnung an Kuckartz (2018)

Der Analyseprozess begann mit dem Import aller Transkripte in MAXQDA und deren Organisation in thematisch relevante Dokumentgruppen, beispielsweise nach Interviewtyp oder Expert*innengruppe. Darauf folgte ein intensives Lesen jedes Dokuments, um ein ganzheitliches Verständnis des Materials zu entwickeln. Während dieses ersten Durchgangs wurden relevante Textstellen mit der Highlighter-Funktion markiert und erste analytische Eindrücke sowie Fragestellungen direkt in Code-Memos festgehalten. Zusätzlich erfolgte die Vergabe von Farb-Labels, um inhaltliche Dimensionen für spätere Codierphasen zu visualisieren. Abschließend wurden die gewonnenen Erkenntnisse, offenen Fragen und Hinweise für die nachfolgende Kategorienbildung zusammengefasst, die als Grundlage für die nächste Analysephase dienten.

Die Hauptkategorien der zweiten Phase wurden induktiv aus den zuvor markierten Textstellen abgeleitet. Zunächst erfolgte eine offene Kodierung, bei der jede relevante Äußerung einen vorläufigen, erklärenden Code erhielt. Diese Codes wurden anschließend systematisch geclustert, um wiederkehrende Themen und Muster zu identifizieren. Aus den resultierenden Themenclustern wurden die Hauptkategorien extrahiert und als oberste Ebene im Kategoriensystem etabliert. Jede Hauptkategorie wurde durch ein ausführliches Code-Memo beschrieben, das die Kategoriendefinition, zentrale Merkmale und Ankerbeispiele als Codierregeln dokumentiert. Die Präzisierung der Kategorien war ein iterativer Prozess: Sie wurden anhand weiterer Textstellen fortlaufend überprüft und geschärft, bis ein kohärentes und trennscharfes Set an Hauptkategorien entstand.

In der dritten Phase erfolgte die systematische Codierung des Datenmaterials anhand der zuvor entwickelten Hauptkategorien. Hierfür wurde jedes Transkript sequenziell durchgearbeitet, um thematisch passende Textpassagen den jeweiligen Kategorien zuzuordnen. Textabschnitte, die sich mehreren Kategorien zuordnen ließen, erhielten eine entsprechende Mehrfachcodierung. Um eine durchgängige Codierkonsistenz zu gewährleisten, wurden die in Phase 2 erstellten Code-Memos regelmäßig konsultiert und als Referenz zur Klärung von Unklarheiten herangezogen.

Im Zuge der vierten Phase erfolgte die kategoriebasierte Aufbereitung der codierten Daten. Hierzu wurden aus der jeweiligen Hauptkategorie zugehörige Textsegmente extrahiert und zur Prüfung der inhaltlichen Kohärenz sowohl isoliert als auch im jeweiligen Dokumentkontext analysiert. Anschließend wurden die Segmente nach Dokumentgruppen und weiteren Merkmalen sortiert, um tiefergehende Muster zu identifizieren. Zentrale Beobachtungen und erste Interpretationsansätze wurden dabei fortlaufend in den Code-Memos dokumentiert.

Den Abschluss bildete die Synthese der wesentlichen Erkenntnisse je Hauptkategorie, welche die Grundlage für die anschließende Bildung von Unterkategorien schuf.

In der fünften Phase wurde das Kategoriensystem durch die Bildung von Unterkategorien weiter ausdifferenziert. Basierend auf den zusammengefassten Textsegmenten jeder Hauptkategorie wurden hierfür gezielt inhaltliche Nuancierungen herausgearbeitet. Dies erfolgte durch eine vertiefte Analyse der Segmente, um spezifische Bedeutungsunterschiede und wiederkehrende Subthemen zu identifizieren. Diese wurden anschließend als neue Unterkategorien unter den jeweiligen Hauptkategorien angelegt, wodurch ein hierarchisch erweitertes Kategoriensystem entstand. Analog zum Vorgehen bei den Hauptkategorien wurde jede Unterkategorie durch ein eigenes Code-Memo mit präzisen Codierregeln definiert und abgesichert.

Das gesamte Datenmaterial wurde in der sechsten Phase einem finalen Codierdurchgang unterzogen, bei dem das erweiterte Kategoriensystem zur Anwendung kam. Jede Textstelle wurde erneut geprüft und den zutreffenden Unterkategorien zugewiesen. Dabei kam wiederholt die Mehrfachcodierung zur Anwendung, um die Vielschichtigkeit von Textpassagen adäquat abzubilden. Zur Sicherung der Codierkonsistenz dienten die in den Phasen 2 und 5 erstellten Code-Memos als stetige Referenz. Auftretende Abweichungen in der Codierung wurden mithilfe der Code-Treffer-Listen identifiziert und in einem separaten Prüfdurchgang systematisch korrigiert.

Die finale Analysephase umfasste die Auswertung der codierten Daten mithilfe des Summary-Grids. Dieses Werkzeug ermöglichte es, die Textsegmente aller Haupt- und Unterkategorien kompiliert darzustellen, um kategorienübergreifende Zusammenhänge sowie Binnendifferenzierungen systematisch zu analysieren. Im Einklang mit dem qualitativen Forschungsdesign wurde bewusst auf quantifizierende Metriken oder Visualisierungen verzichtet, um den Fokus vollständig auf die interpretative Analyse der Inhalte zu legen. Die detaillierten Ergebnisse dieser inhaltsanalytischen Auswertung werden in Kapitel 5.2 präsentiert.

Um die methodische Nachvollziehbarkeit des gesamten Analyseprozesses zu gewährleisten, wurden sämtliche Informationen in MAXQDA dokumentiert. Eine systematische Memoführung diente dabei der transparenten Darstellung aller analytischen Überlegungen und methodischen Entscheidungen. Das vollständige Kategoriensystem ist dem Anhang F beigefügt und schließt die methodische Dokumentation ab.

4.3.1.3 Qualitätssicherung und Reflexion zum induktiven Ansatz

Im Einklang mit dem hermeneutisch-rekonstruktiven Paradigma qualitativer Forschung wurde die methodische Güte nicht durch statistische Reliabilitätskoeffizienten sichergestellt, sondern durch die Gewährleistung von Transparenz, Reflexivität und Nachvollziehbarkeit (Flick, 2016; Lincoln & Guba, 1985). Diese wurde durch eine Kombination aus methodischer Stringenz in der Anwendung der Prozessschritte nach Kuckartz (2018), einer lückenlosen Dokumentation aller Analyseschritte sowie einer fortlaufenden kritischen Reflexion des Forschungsprozesses erreicht. Die kommunikative Validierung der Ergebnisse durch eine Rückkopplung mit den Interviewpartner*innen ist als separates Gütekriterium vorgesehen und erfolgt erst in der nachgelagerten dritten Forschungsphase.

4.3.2 Qualitative Inhaltsanalyse nach Kuckartz (deduktiv-induktiv) – Dokumentenanalyse

4.3.2.1 Datenbasis und Transkription

Für die Dokumentenanalyse wurde ausschließlich das Medienformat Podcast herangezogen. Insgesamt wurden 32 Podcastfolgen (Abbildung 7) ausgewählt, vollständig transkribiert und bereinigt. Im Rahmen der Transkriptionen wurden die gleichen Regeln angewandt, wie sie bereits im Kontext der Expert*inneninterviews zur Anwendung kamen. Die Kriterien, die zur Selektion der Podcastfolgen herangezogen wurden, sind bereits im vorangegangenen Kapitel definiert worden und werden an dieser Stelle nicht erneut ausgeführt.

Aufbauend auf den dargelegten Prinzipien zur Qualitätssicherung, erfolgt nun die Beschreibung des zweiten Analyseschritts. Um die aus den Expert*inneninterviews gewonnenen Erkenntnisse zu erweitern und durch eine weitere Datenquelle zu triangulieren, wird eine qualitative Inhaltsanalyse von Dokumenten durchgeführt. Das nachfolgende Kapitel erläutert hierzu die methodische Vorgehensweise.

4.3.2.2 Hinweis zum analytischen Vorgehen zur qualitativen Inhaltsanalyse

Das analytische Vorgehen bei der Auswertung der Podcast-Transkripte baut direkt auf der in Kapitel 4.3.1.2 beschriebenen Vorgehensweise nach Kuckartz (2018) auf. Ein zentrales Merkmal dieser Methodik ist ihr iterativer Charakter, der explizit kein starres, lineares Abarbeiten der Phasen vorsieht, sondern eine flexible Anpassung des Kategoriensystems ermöglicht (Kuckartz, 2018). Dieser Grundsatz wird genutzt, um das auf Basis der Expert*inneninterviews entwickelte Kategoriensystem durch die Analyse der Podcasts zu validieren,

zu differenzieren und zu erweitern. Somit gliedert sich der Prozess in zwei Hauptphasen, bestehend aus der deduktiven Anwendung und der induktiven Erweiterung.

Zunächst wurde das bestehende Kategoriensystem – resultierend aus den Expert*inneninterviews – als deduktive Grundlage auf die gesamten Transkripte der Podcastfolgen angewendet. Textpassagen, die sich den vorhandenen Kategorien eindeutig zuordnen ließen, wurden entsprechend kodiert. Gemäß dem Prinzip der Offenheit wurden im Anschluss neue, relevante Aspekte aus den Podcastfolgen, die vom bisherigen Kategoriensystem noch nicht erfasst wurden, durch die Bildung neuer, induktiver Kategorien am Material ergänzt. Dieser systematische Wechsel zwischen deduktiver Anwendung und induktiver Erweiterung führte zu einer fortlaufenden Anpassung und Finalisierung des Kategoriensystems. Dadurch wird sichergestellt, dass die relevanten Inhalte aus beiden Datenquellen – den Expert*inneninterviews und den Podcasts – umfassend und trennscharf abgebildet sind. Das konsolidierte Kategoriensystem ist in Anhang F dokumentiert. Schließlich erfolgte die Analyse der Podcast-Transkripte unter Anwendung des konsolidierten Kategoriensystems.

4.3.2.3 Qualitätssicherung und Reflexion zum deduktiv-induktiven Ansatz

Die Nachvollziehbarkeit und methodische Qualität wurden durch eine detaillierte Dokumentation aller Schritte der Kategorienbildung und -anpassung sichergestellt (Rädiker & Kuckartz, 2019). Ein zentrales Instrument hierfür war die fortlaufende Pflege von Code-Memos, die für jede Kategorie Definitionen, Ankerbeispiele und Kodierregeln enthielten. Zudem wurden sämtliche Anpassungen am Kategoriensystem inklusive ihrer Begründungen kontinuierlich protokolliert. Zusätzlich wurden die Ergebnisse der Dokumentenanalyse systematisch mit den Ergebnissen der Expert*inneninterviews verglichen und trianguliert (Flick, 2016; Rädiker & Kuckartz, 2019). Ziel des Abgleichs war die Identifizierung von Überschneidungen, Ergänzungen und neuen Perspektiven, um eine möglichst umfassende empirische Basis zu schaffen.

Die Erkenntnisse aus beiden Analyseschritten wurden im weiteren Verlauf für die Entwicklung eines integrativen Implementierungsframeworks genutzt. Die detaillierte methodische Ableitung und Validierung des Frameworks werden im folgenden Kapitel dargestellt.

4.3.3 Ableitung des Implementierungsframeworks

4.3.3.1 Zielsetzung und methodische Einordnung

Die Entwicklung des Implementierungsframeworks basiert auf einer methodisch fundierten Kombination zweier etablierter Ansätze: dem Design Science Research (DSR) nach Hevner et al. (2004) und dem Conceptual Framework Development nach Jabareen (2009). Diese theoretische Fundierung gewährleistet sowohl die wissenschaftliche Rigorosität als auch die Praxisrelevanz des resultierenden Frameworks. Dabei stellt das DSR einen gestaltungsorientierten Forschungsansatz dar, der darauf abzielt, innovative Artefakte – wie Frameworks, Modelle oder Methoden – zu entwickeln und deren Nutzen systematisch zu evaluieren. Hierzu folgt es einem iterativen Zyklus, der die Identifikation eines relevanten Problems, die Entwicklung und theoretische Adaption eines Artefakts sowie dessen Evaluation und Kommunikation umfasst (Hevner et al., 2004). Dieser Ansatz ist besonders geeignet, wenn das Ziel die Entwicklung und Validierung eines Frameworks ist, da es die Verbindung zwischen wissenschaftlicher Strenge und praktischer Anwendbarkeit methodisch absichert. Ergänzend dazu erweitert das Conceptual Framework Development nach Jabareen (2009) den gestaltungsorientierten Ansatz des DSR um eine theoriebasierte, konzeptuelle Perspektive. Jabareen (2009) beschreibt hierzu einen iterativen Prozess, der die Identifikation, Analyse und Konsolidierung zentraler theoretischer und empirischer Konzepte umfasst. Ziel ist es, ein kohärentes, theoretisch fundiertes Framework zu entwickeln, das komplexe Phänomene systematisch strukturiert und zugänglich macht. Die Offenheit und Flexibilität dieses Ansatzes ist insbesondere bei interdisziplinären und dynamischen Forschungsgegenständen – wie der Implementierung generativer KI – vorteilig.

Die Kombination beider Ansätze ermöglichte es, die Entwicklung des Implementierungsframeworks sowohl theoriegeleitet als auch empirisch fundiert zu gestalten. Während Hevner et al. (2004) die strukturierte Entwicklung, Adaption und Evaluation des Frameworks sichert, gewährleistet das Vorgehen nach Jabareen (2009) die konzeptionelle Fundierung und die iterative Integration empirischer Erkenntnisse. Diese methodische Verschränkung bildete schließlich die Grundlage für ein Implementierungsframework, das den Anforderungen wissenschaftlicher Nachvollziehbarkeit und praktischer Anschlussfähigkeit gleichermaßen gerecht wird.

4.3.3.2 Festlegung methodischer Schritte zur Framework-Entwicklung

Die Ableitung des Implementierungsframeworks folgte einem strukturierten, mehrstufigen Prozess, der sich an den methodologischen Prinzipien von Hevner et al. (2004) und Jabareen (2009) orientiert. Die nachfolgende Abbildung 9 erläutert für jeden Prozessschritt das methodische Ziel, die theoretische Fundierung sowie die konkrete Umsetzung und wird durch eine schematische Abbildung visuell unterstützt.



Abbildung 9: Prozessschritte zur Ableitung des Implementierungsframeworks

Quelle: Eigene Darstellung in Anlehnung an Hevner et al. (2004) und Jabareen (2009)

(1) Problemdefinition und Zielsetzung

Der erste Prozessschritt, orientiert am DSR-Ansatz, diente der präzisen Definition des Problems und der Ableitung klarer Zielsetzungen für das zu entwickelnde Implementierungsframework. Die methodische Grundlage hierfür bildete eine systematische Analyse des Forschungsfeldes, um die Relevanz und Tragweite der Problemstellung zu erfassen. Die abgeleiteten Zielsetzungen wurden dabei so konzipiert, dass sie sowohl wissenschaftliche als auch praxisbezogene Anforderungen erfüllen.

(2) Konzeptmapping

Das Konzeptmapping erfolgte nach Jabareen (2009) und diente der Identifikation, Analyse und Strukturierung zentraler theoretischer und empirischer Konzepte, die für die Entwicklung des Implementierungsframeworks im zweiten Prozessschritt relevant waren. In diesem Schritt wurden relevante theoretische Modelle aus Kapitel 3.3 sowie die Ergebnisse der qualitativen Inhaltsanalyse aus Kapitel 5.2 systematisch erfasst und in Beziehung zueinander gesetzt. Ziel war es, die Konzeptionsbasis für das Implementierungsframework zu schaffen und zentrale Einflussfaktoren sowie deren Wechselwirkungen sichtbar zu machen.

(3) Konsolidierung

Auf Basis beider methodologischer Ansätze führte der dritte Prozessschritt die im Konzeptmapping identifizierten Konzepte zu einem ersten, kohärenten Framework-Entwurf zusammen. Dieser konstruktive Prozess erfolgte iterativ, indem die konzeptuellen Bausteine durch

wechselseitigen Abgleich zu einem konsistenten Gesamtmodell integriert wurden. Das Ergebnis war ein validierungsfähiger Erstentwurf, der die Grundlage für die nachfolgende Evaluationsphase bildete.

(4) Validierung und iterative Weiterentwicklung

Der vierte Prozessschritt widmete sich der Validierung und iterativen Weiterentwicklung des Implementierungsframeworks, basierend auf den Prinzipien beider Ansätze. Hierfür wurde der Erstentwurf mittels gezieltem Member Checking überprüft und fortlaufend optimiert. Die systematische Auswertung der Rückmeldungen erfolgte dabei mittels der Framework Analysis, um die gewonnenen Erkenntnisse gezielt in die Weiterentwicklung des Implementierungsframeworks zu integrieren. Das übergeordnete Ziel dieses iterativen Prozesses galt der kontinuierlichen Steigerung von Praxisrelevanz, Verständlichkeit und Anwendbarkeit.

(5) Theoretische Adaption des Implementierungsframeworks

Mit der exemplarischen Anwendung des Implementierungsframeworks innerhalb des Marketingprozesses wurde im fünften Prozessschritt, dessen Anwendbarkeit, Konsistenz und Praxistauglichkeit evaluiert. Diese praktische Erprobung, die sich am DSR-Ansatz orientierte, diente zugleich als abschließender Nachweis der Nützlichkeit und Validität des Implementierungsframeworks. Schließlich soll die theoretische Adaption ein Szenario aus der mittelständischen Unternehmenspraxis abbilden.

4.3.3.3 Qualitätssicherung und Reflexion der Framework-Entwicklung

Die Sicherung der wissenschaftlichen Qualität und Nachvollziehbarkeit des methodischen Vorgehens ist jederzeit ein zentrales Anliegen dieser Forschungsarbeit. Hierzu wurde eine vollständige Dokumentation aller methodischen Schritte, die Offenlegung der Auswahl- und Analyseverfahren sowie die systematische Archivierung der Daten (z. B. Transkripte, Kodierprotokolle) dargelegt, um eine lückenlose Nachvollziehbarkeit des Forschungsprozesses zu ermöglichen (Flick, 2016; Mey & Mruck, 2020; Steinke, 1999). Die Validität der Ergebnisse wurde durch die methodische Triangulation unterschiedlicher Datenquellen und Analyseverfahren gestärkt. Die Kombination aus Expert*inneninterviews und Dokumentenanalyse gewährleistete eine multiperspektivische und robuste empirische Basis (Döring, 2023). Dabei trug die iterative Überprüfung und Anpassung des Frameworks auf Basis von Expert*innenfeedback und empirischen Erkenntnissen zur kontinuierlichen Optimierung und Praxisrelevanz bei (Hevner et al., 2004; Jabareen, 2009).

Nachdem die methodischen Grundlagen sowie die Gütesicherung der Framework-Entwicklung dargelegt wurden, folgt nun der Schritt der Framework-Validierung. Das nachfolgende Kapitel beschreibt die dritte Forschungsphase, in der das entwickelte Implementierungsframework durch gezieltes Expert*innenfeedback finalisiert und zur Anwendungsreife gebracht wurde.

4.4 Phase 3: Validierung und Finalisierung Implementierungsframework

4.4.1 Member Checking

4.4.1.1 Zielsetzung und methodische Einordnung

Das Member Checking stellt einen zentralen Validierungsschritt bei der Entwicklung des Implementierungsframeworks dar. Ziel dieses Verfahrens besteht darin, die identifizierten Dissenspunkte mit den Expert*innen zu diskutieren und auf dieser Basis einen weitestgehenden Konsens zu erreichen. In der qualitativen Forschung wird das Member Checking als ein etabliertes Verfahren zur Sicherung der Glaubwürdigkeit und Validität von Forschungsergebnissen bezeichnet (Birt et al., 2016; Lincoln & Guba, 1985). Die Expert*innen stellen durch die Rückkopplung sicher, dass die entwickelten Framework-Komponenten nicht nur theoretisch fundiert, sondern auch in der Praxis anwendbar und nachvollziehbar sind.

Im Rahmen der Forschungsarbeit fungiert das Member-Checking somit als Instrument zur Validierung der bisherigen Framework-Komponenten, zur Identifikation weiterer Optimierungspotenziale sowie zur Überprüfung der Praxistauglichkeit. Es stellt demnach einen wesentlichen Bestandteil eines iterativen Entwicklungsprozesses dar. Durch die Rückmeldungen der Expert*innen können Unklarheiten, Lücken oder praxisferne Aspekte frühzeitig erkannt und gezielt adressiert werden. Die methodische Einbettung folgt ebenso dem pragmatischen Forschungsparadigma, sodass die Nützlichkeit und Anwendbarkeit von Wissen für die Praxis als zentrales Kriterium wissenschaftlicher Qualität im Vordergrund steht (Feilzer, 2010; Maarouf, 2019).

4.4.1.2 Auswahl und Rekrutierung der Validierungsexpert*innen

Insgesamt wurden sieben Expert*innen aus dem bereits rekrutierten Personenstamm auf Basis ihres Expertisescores ausgewählt. In der qualitativen Forschung ist die Auswahl einer vergleichsweise kleinen Gruppe von Validierungsexpert*innen methodisch legitimiert. In diesem Forschungsansatz liegt der Fokus auf der Tiefe und Qualität der Rückmeldungen,

nicht auf der statistischen Repräsentativität (Creswell & Poth, 2018; Guest et al., 2006; Malterud et al., 2016). Insbesondere im Kontext von Member-Checking-Prozessen wird häufig eine begrenzte Anzahl besonders erfahrener Expert*innen einbezogen, um eine intensive, dialogische Validierung und eine gezielte Rückkopplung zu gewährleisten. Diese Konzentration hat zum Ziel, die Aussagekraft und Praxisrelevanz der erhaltenen Rückmeldungen zu erhöhen und somit zu einer theoretischen Sättigung im Validierungsprozess beizutragen. In der qualitativen Forschung wird dies als Gütekriterium für die Qualität empirischer Erkenntnisse betrachtet (Glaser et al., 2010).

Die Rekrutierung der Teilnehmenden erfolgte durch eine erneute Kontaktaufnahme und die Auswahl basierte auf den im Scoring-Modell definierten Schwellenwerten für exzellente Expertise und wurde transparent dokumentiert. Um eine multiperspektivische Validierung zu gewährleisten, wurde die Gruppe bewusst heterogen zusammengestellt: Sie umfasste sowohl interne Akteur*innen (Führungskräfte, Fachexpert*innen) als auch externe Stakeholder (Berater*innen, Implementierungspartner*innen). Diese Heterogenität sicherte die Berücksichtigung unterschiedlicher Sichtweisen und Rollen im Implementierungsprozess (Creswell & Plano Clark, 2018). Zur Vorbereitung auf die Validierungsgespräche erhielten die Expert*innen eine Zusammenfassung des Framework-Entwurfs sowie einen Leitfaden mit zentralen Fragestellungen, um eine fundierte Rückmeldung zu ermöglichen. Die Entwicklung des bereitgestellten Leitfadens wird im folgenden Kapitel vorgestellt.

4.4.1.3 Entwicklung des halbstrukturierten Interviewleitfadens

Die Entwicklung des Interviewleitfadens für die dritte Forschungsphase diente der gezielten Validierung des Framework-Entwurfs hinsichtlich seiner Verständlichkeit, Praxisnähe und Anschlussfähigkeit. Der Leitfaden fokussiert sich dabei bewusst auf jene Aspekte, bei denen die vorangegangenen Analysen Dissenspunkte oder kontroverse Ergebnisse aufzeigten. Das übergeordnete Ziel der Gespräche war es, Konsenslinien zu identifizieren, kontextsensitive Wenn-dann-Entscheidungsregeln abzuleiten und Minimalanforderungen zu präzisieren.

Die Fragengestaltung folgte einem deduktiven Vorgehen. Ausgangspunkt waren die in Kapitel 5.2.3 extrahierten Dissenspunkte und kontroversen Ergebnisse. Diese wurden in offene Leitfragen mit maximal zwei vertiefenden Nachfragen je Themenblock überführt. Um differenzierte, kontextreiche Rückmeldungen zu ermöglichen und die Vergleichbarkeit zwischen den Fällen sicherzustellen, verzichteten die Fragen bewusst auf binäre Antwortformate

oder Skalierungen. Die Validierungsinterviews wurden in einer einheitlichen Leitfadenfassung durchgeführt, sodass Varianten für interne bzw. externe Perspektiven nicht vorgesehen waren.

Die Struktur des Leitfadens ist dreiteilig angelegt worden. Nach einer kurzen Einleitung, in der Gesprächszweck und Ablauf in komprimierter Form dargelegt wurden, folgte der Hauptteil mit zwei Segmenten: (1) eine Gesamtvalidierung des Frameworks mittels offener Fragen zur Plausibilität der Gesamtstruktur, zur Anschlussfähigkeit im KMU-Kontext sowie zur Identifikation konkreter Optimierungspunkte und (2) die fokussierte Diskussion der Dissenspunkte als Kernteil. Die Dissenspunkte wurden in vier standardisierten Themenblöcken behandelt – Implementierungsstrategie und Steuerungslogiken (Kürzel: STRAT), Technologieauswahl, Deployment-Optionen und Integrationsgrad (Kürzel: TECH), Erfolgsmessung und Wirkungen (Kürzel: EVAL) und KI-Roadmap und Zukunftsausrichtung (Kürzel: FUT). In jedem Block wurde eine Leitfrage gestellt, die mit maximal zwei Nachfragen ergänzt wurde. Der Erstentwurf des Leitfadens kann dem Anhang G entnommen werden.

Nachdem die inhaltliche und strukturelle Konzeption des Interviewleitfadens abgeschlossen war, musste dessen praktische Eignung für die Feldphase sichergestellt werden. Aus diesem Grund wurde vor dem eigentlichen Beginn der Validierungsgespräche ein systematischer Pretest durchgeführt, um die Verständlichkeit, den Gesprächsfluss und die Ergebnisqualität des Instruments zu überprüfen und zu optimieren.

4.4.1.4 Durchführung Pretest und Optimierung Interviewleitfaden

Der Pretest des Leitfadens wurde vor Beginn der Feldphase durchgeführt, um die finale Fassung systematisch auf Verständlichkeit, Gesprächsfluss und Output-Tauglichkeit zu prüfen. Ziel war es, sicherzustellen, dass die in Kapitel 4.4.1.3 definierte offene Fragearchitektur die intendierten Ergebnisse je Kontroverse zuverlässig hervorbringt. Methodisch erfolgte der Pretest anhand von drei Pilotgesprächen. Als Prüfgrößen dienten neben der inhaltlichen Eignung der Fragen insbesondere die Zeitökonomie (Zielzeit 40–45 Minuten), die Vermeidung binärer Antwortmuster sowie die Vergleichbarkeit der Rückmeldungen.

Die Ergebnisse des Pretests führten zu mehreren präzisen Anpassungen am Leitfaden. So wurden Formulierungen sprachlich geschärft, um differenzierte, nicht-binäre Antworten zu stimulieren, und die Reihenfolge der vier Dissensblöcke zur Erhöhung der Vergleichbarkeit standardisiert. Darüber hinaus wurde je Block ein Abschlussimpuls zur Pointierung der Ergebnisse ergänzt und die Einleitung für einen raschen Einstieg in den Kernteil gestrafft. Die

im Pretest bestätigte Einhaltung der Zielzeit sowie die Eignung der standardisierten Blocklogik zur Generierung konsistenter Rückmeldungen untermauerten die finale Designentscheidung für den Leitfaden in Anhang H.

4.4.1.5 Durchführung und Dokumentation des Member Checkings

Das Member Checking erfolgte in Form von semistrukturierten Validierungsgesprächen, die online via Microsoft Teams mit einer Dauer von jeweils 40 bis 50 Minuten stattfanden. Nach Einholung der Zustimmung wurden alle Gespräche aufgezeichnet und anschließend transkribiert. Die konsequente Anwendung der zuvor definierten Transkriptionsregeln stellte dabei eine einheitliche und nachvollziehbare Datenbasis für die Auswertung sicher. Ergänzend wurden Interviewprotokolle angefertigt, um nonverbale Signale und unmittelbare analytische Eindrücke festzuhalten.

Die Validierungsinterviews zielten auf eine Bewertung des Implementierungsframeworks ab. Ein erster Schwerpunkt lag auf der Verständlichkeit und Nachvollziehbarkeit der einzelnen Komponenten. Hierbei sollten die Expert*innen beurteilen, inwieweit die Struktur und die Inhalte des Frameworks als klar und logisch konsistent wahrgenommen werden. Ferner wurde die Praxisrelevanz und Anwendbarkeit im spezifischen Kontext mittelständischer Unternehmen thematisiert. Von besonderem Interesse war hierbei die Frage, ob die vorgeschlagenen Schritte und Maßnahmen als realistisch und auf den Unternehmensalltag übertragbar eingeschätzt werden. Ein dritter Aspekt betraf die Vollständigkeit des Frameworks. Die Expert*innen wurden gebeten zu bewerten, ob alle wesentlichen Phasen und Aufgaben der Implementierung abgebildet sind, und gleichzeitig auf potenzielle Lücken, Redundanzen oder Unklarheiten in der Struktur hinzuweisen. Abschließend wurden die Teilnehmenden um konkrete Vorschläge zur Optimierung und Weiterentwicklung gebeten, um praxisnahe und empirisch fundierte Impulse für die finale Ausgestaltung des Frameworks zu gewinnen.

Nach Abschluss der Datenerhebung lag ein umfangreicher Korpus an Expert*innenfeedback vor. Um diese Daten auszuwerten und die vielfältigen Rückmeldungen in die Weiterentwicklung des Implementierungsframeworks zu integrieren, bedurfte es einer geeigneten Analyseverfahren. Das folgende Kapitel stellt daher die gewählte Methode – die Framework Analysis – und ihre methodische Einordnung vor.

4.4.2 Framework Analysis

4.4.2.1 Zielsetzung und methodische Einordnung

Die Framework Analysis stellt einen zentralen methodischen Baustein im Validierungsprozess zur Weiterentwicklung des Implementierungsframeworks dar. Ziel der Analysemethode ist es, die Kohärenz des Frameworks systematisch zu überprüfen, bestehende Lücken und Widersprüche zu identifizieren sowie die empirische Fundierung der einzelnen Framework-Komponenten sicherzustellen. Darüber hinaus dient sie der strukturierten Ableitung von Optimierungsvorschlägen sowie Handlungsempfehlungen.

Die Entscheidung für die Framework Analysis leitet sich unmittelbar aus den genannten Zielsetzungen ab. Insbesondere der systematische Vergleich des Expert*innenfeedbacks sowie die empirische Fundierung des Implementierungsframeworks ließen sich mit dieser Methode in besonderer Tiefe und Nachvollziehbarkeit realisieren. Die Analysemethode stellt demnach ein etabliertes Verfahren in der qualitativen Sozialforschung dar, das sich durch eine hohe Transparenz, Strukturierung und Nachvollziehbarkeit auszeichnet (Gale et al., 2013; Rädiker & Kuckartz, 2019). Weitere relevante methodische Beiträge stammen von Ritchie & Spencer (2002), die das Verfahren ursprünglich im Kontext der angewandten Sozialforschung etabliert haben. Insbesondere bei der Analyse umfangreicher und komplexer Datenbestände, wie sie im Rahmen von Expert*inneninterviews und Member-Checking-Prozessen entstehen können, findet die Framework Analysis Anwendung. Durch die explizite Bezugnahme auf die Framework Analysis nach Gale et al. (2013) sowie die methodischen Standards der qualitativen Inhaltsanalyse nach Kuckartz (2018) wird eine wissenschaftlich fundierte und zugleich praxisorientierte Validierung des Frameworks gewährleistet.

Im Gesamtkontext der Forschungsarbeit übernimmt die Framework Analysis eine zentrale Brückenfunktion: Sie sichert den Transfer zwischen den Ergebnissen und der theoretischen Modellbildung. Damit leistet sie einen maßgeblichen Beitrag zur Erfüllung der wissenschaftlichen Anforderungen an Validität und Nachvollziehbarkeit. Zudem gewährleistet sie, dass das Implementierungsframework für die Praxis mittelständischer Unternehmen handlungsleitend und anschlussfähig bleibt (Feilzer, 2010; Maarouf, 2019).

4.4.2.2 Analytisches Vorgehen zur Framework Analysis

Das analytische Vorgehen folgt einem strukturierten, mehrstufigen Prozess, der in der qualitativen Forschungspraxis etabliert ist (Gale et al., 2013; Ritchie & Spencer, 2002). Er gliedert sich in drei wesentliche Schritte, die innerhalb der nachfolgenden Abschnitte erläutert werden.

Der erste Schritt, die Familiarisierung, umfasste ein intensives Lesen aller Transkripte. Während dieses Durchgangs wurden erste Notizen zu wiederkehrenden Themen, markanten Aussagen und auffälligen Mustern festgehalten, um ein tiefgreifendes Verständnis für die inhaltliche Breite und Tiefe der Datenbasis zu entwickeln.

Im zweiten Schritt wurde das für die Analyse erforderliche Kategoriensystem festgelegt. Anstatt ein neues System induktiv abzuleiten, wurde auf das konsolidierte Kategoriensystem aus der zweiten Forschungsphase zurückgegriffen (siehe Anhang F). Eine Überarbeitung des Systems, wie sie nach Kuckartz (2018) methodisch möglich gewesen wäre, war nicht erforderlich, da die bestehenden Kategorien bereits alle für die Framework Analysis relevanten Aspekte abdeckten. Dies umfasst die vier zentralen Themenbereiche, die sich aus den Dissenspunkten ableiten (Implementierungsstrategie, Technologieauswahl, Erfolgsmessung und KI-Roadmap), sowie die fünfte Kategorie zur Plausibilität und Realisierbarkeit des Frameworks. Die Verwendung des Kategoriensystems stellte sicher, dass die Analyse direkt auf den bisherigen Erkenntnissen aufbauen konnte.

Der dritte Schritt umfasste die Codierung der Daten anhand des Kategoriensystems und die anschließende Zusammenfassung der codierten Segmente in einer Datenmatrix. In dieser wurden die Fälle (Zeilen) den Kategorien (Spalten) gegenübergestellt, um einen direkten fall- und themenübergreifenden Vergleich zu ermöglichen. Die abschließende Interpretation der Matrix zielte darauf ab, Konsens und Dissens zu identifizieren. Die hieraus gewonnenen Erkenntnisse bildeten die empirische Grundlage für die Ableitung von Optimierungsvorschlägen zur finalen Ausgestaltung des Implementierungsframeworks.

4.4.2.3 Dokumentation des Auswertungsprozesses

Zur Sicherstellung der Nachvollziehbarkeit und methodischen Qualität wurde der gesamte Analyseprozess lückenlos dokumentiert. Diese Dokumentation umfasste alle Arbeitsschritte – von der Entwicklung des thematischen Rahmenwerks über die Codierung in MAXQDA bis hin zur Matrixbildung und Interpretation. Ebenso wurden die Zuordnung der Ergebnisse zu den Framework-Komponenten sowie die iterativen Anpassungen am Framework selbst

systematisch protokolliert. Die detaillierte Darstellung der inhaltlichen Ergebnisse und die finale Ausgestaltung des Frameworks folgen im anschließenden Kapitel 5.

Nachdem die einzelnen Phasen des Forschungsdesigns und der Datenauswertung detailliert dargelegt wurden, schließt das Methodik-Kapitel mit einer übergeordneten Reflexion ab. Bevor die Ergebnisse in Kapitel 5 präsentiert werden, erfolgt im nachfolgenden Kapitel eine systematische Bewertung des gesamten methodischen Vorgehens anhand etablierter Gütekriterien. Dieser Schritt dient dazu, die wissenschaftliche Qualität und Rigorosität der Forschungsarbeit explizit zu begründen.

4.5 Retrospektive: Qualitative Gütekriterien und Praxisanforderungen

4.5.1 Ziel und Stellenwert der retrospektiven Betrachtung

Die retrospektive Betrachtung des methodischen Vorgehens ist ein zentrales Element der Qualitätssicherung und gilt in der qualitativen Sozialforschung als Voraussetzung für Glaubwürdigkeit und Nachvollziehbarkeit (Flick, 2016; Kuckartz, 2018; Lincoln & Guba, 1985; Mayring, 2022; Steinke, 1999). Dementsprechend erfolgt in dieser Forschungsarbeit eine kritische Reflexion des gesamten Methodenkapitels, die auf eine systematische Bewertung des Vorgehens abzielt. Zum einen wird die Einhaltung anerkannter wissenschaftlicher Gütekriterien wie Transparenz, Nachvollziehbarkeit, Validität, Reflexivität, Triangulation, Kohärenz und Transferierbarkeit überprüft (Flick, 2016; Gale et al., 2013; Mayring, 2022). Zum anderen wird evaluiert, inwieweit das methodische Design die Generierung praktisch relevanter und anwendbarer Ergebnisse sichergestellt hat.

Die Bedeutung dieser Retrospektive liegt in der Notwendigkeit, wissenschaftliche Rigorosität mit praktischer Anschlussfähigkeit zu verbinden (Creswell & Plano Clark, 2018; Feilzer, 2010). Insbesondere der gewählte qualitativ-explorative Ansatz im Rahmen eines pragmatistischen Forschungsparadigmas erfordert eine solche kritische Selbstreflexion (Gale et al., 2013; Maarouf, 2019). Daher bewertet die Retrospektive das Vorgehen nicht nur anhand wissenschaftlicher Gütekriterien, sondern ebenso kritisch anhand der spezifischen Anforderungen mittelständischer Unternehmen. Diese umfassen Kriterien der unmittelbaren Anwendbarkeit wie Verständlichkeit und Umsetzbarkeit, Aspekte der organisatorischen Passung wie Flexibilität und Prozessintegration (Oldemeyer et al., 2024; Rajaram & Tinguely, 2024) sowie die entscheidende Forderung nach einem messbaren Nutzen (Enshassi et al., 2024; Hansen et al., 2024; Mikalef et al., 2023).

Die folgende retrospektive Analyse wird daher von zwei zentralen Leitfragen geleitet: Inwieweit wurden die wissenschaftlichen Gütekriterien im Forschungsprozess eingehalten und in welchem Maße konnte das methodische Vorgehen den Anforderungen der Praxis gerecht werden? Die Beantwortung dieser beiden Fragen sichert die Grundlage für eine transparente, nachvollziehbare und praxisrelevante Forschung.

4.5.2 Anwendung qualitativer Gütekriterien im Forschungsprozess

4.5.2.1 Transparenz und Nachvollziehbarkeit

Die Transparenz und Nachvollziehbarkeit des Forschungsprozesses wurde durch eine umfassende und detaillierte Dokumentation sämtlicher methodischer Entscheidungen und Arbeitsschritte gewährleistet. Dies beinhaltete die Offenlegung der Auswahl- und Rekrutierungsprozesse für die Expert*innen. Zudem wurde die Entwicklung und Anwendung eines klar strukturierten Codebuchs berücksichtigt. Auch die iterative Überprüfung und Anpassung der Kategorien sowie die vollständige Protokollierung der Datenaufbereitung und -analyse waren Teil dessen. Die Verwendung von MAXQDA erlaubte eine systematische Archivierung und Rückverfolgbarkeit aller Kodierungen und Analysewege. Darüber hinaus wurden sämtliche Transkripte, Kodierregeln und Zwischenergebnisse sorgfältig dokumentiert, sodass die Herleitung der Ergebnisse und die Entwicklung des Implementierungsframeworks für Dritte transparent und nachvollziehbar sind (Flick, 2016; Kuckartz, 2018; Mayring, 2022; Steinke, 1999).

4.5.2.2 Validität und Triangulation

Zur Stärkung der Validität wurde eine methodische Triangulation eingesetzt, die verschiedene Datenquellen und Analyseverfahren systematisch kombinierte. Die Kombination aus unterschiedlichen Erhebungsformen (Expert*inneninterviews, Dokumentenrecherche, Validierungsgespräche) und jeweils darauf abgestimmten Analyseverfahren schuf eine multiperspektivische und robuste empirische Basis für die Forschungsergebnisse.

Konkret umfasste die Triangulation mehrere methodische Ebenen. Die Auswahl der Expert*innen wurde durch ein Scoring-Modell systematisiert. Für die Auswertung der Primärdaten kam die qualitative Inhaltsanalyse nach Kuckartz (2018) zum Einsatz, dessen Kategoriensystem flexibel angepasst wurde: rein induktiv für die explorativen Expert*inneninterviews und deduktiv-induktiv für die strukturierteren Dokumentenrecherchen. Die Daten aus

den Validierungsgesprächen (Member Checking) wurden schließlich mittels der Framework Analysis gezielt auf die Optimierung des Frameworks hin ausgewertet.

Die Kombination dieser unterschiedlichen Erhebungs- und Analyseformen realisierte eine methodisch fundierte Triangulation, welche die interne Validität und argumentative Plausibilität der Forschungsergebnisse erhöhte. Zusätzlich sicherte der stetige Abgleich der Kategorien und Framework-Komponenten mit den empirischen Daten deren inhaltliche Konsistenz und argumentative Fundierung (Flick, 2016; Gale et al., 2013; Lincoln & Guba, 1985).

4.5.2.3 Kohärenz und Transferierbarkeit

Die Gewährleistung von Kohärenz und Transferierbarkeit wurde durch eine konsequente Abstimmung aller methodischen Schritte auf das Forschungsziel und die theoretische Fundierung sichergestellt. Die innere Stimmigkeit des Forschungsdesigns, die logische Verknüpfung der einzelnen Analysephasen und die Konsistenz der Argumentation wurden fortlaufend überprüft. Die detaillierte Kontextualisierung der Ergebnisse, die Beschreibung der Stichprobe sowie die Reflexion der spezifischen Rahmenbedingungen des deutschen Mittelstands ermöglichten eine Einschätzung, inwieweit das entwickelte Implementierungsframework übertragbar ist. Die Ableitung praxisorientierter Handlungsempfehlungen und die Diskussion der Limitationen trugen dazu bei, die Übertragbarkeit und Anschlussfähigkeit der Forschungsergebnisse für unterschiedliche mittelständische Unternehmen zu bewerten (Flick, 2016; Lincoln & Guba, 1985; Mayring, 2022).

4.5.2.4 Herausforderungen im Forschungsprozess

Trotz der konsequenten Einhaltung qualitativer Gütekriterien traten im Verlauf des Forschungsprozesses spezifische Herausforderungen auf, die kritisch zu reflektieren sind. Ein zentrales Spannungsfeld bestand zwischen dem Anspruch wissenschaftlicher Rigorosität und der Notwendigkeit praxisorientierter Flexibilität. Die Operationalisierung von Kategorien und die Integration heterogener Datenquellen – insbesondere die Kombination von Expert*inneninterviews, Podcastfolgen und Validierungsgesprächen – erforderten eine kontinuierliche methodische Anpassung, die als Ausdruck reflexiver Forschungspraxis zu verstehen ist und zur Robustheit der Ergebnisse beitrug. Zudem war die Übertragbarkeit der Ergebnisse auf unterschiedliche Unternehmenskontexte von Beginn an als bewusste Forschungsentscheidung angelegt: Im Sinne qualitativer Forschungslogik wurde nicht statistische Generalisierbarkeit, sondern kontextgebundene Übertragbarkeit angestrebt – ein An-

spruch, dem das vorliegende Design durch die Kombination aus purposivem Sampling, methodischer Triangulation und Member Checking systematisch Rechnung trägt. Die Auswahl der Expert*innen folgte einem strukturierten Scoring-Modell und orientierte sich am Prinzip der theoretischen Sättigung; die Verfügbarkeit relevanter Podcastfolgen wurde durch ein systematisches Dokumentenauswahlverfahren gesteuert. Beide Entscheidungen sind damit nicht als externe Begrenzung, sondern als methodisch begründete Rahmensetzung zu verstehen.

Die strukturelle Heterogenität des deutschen Mittelstands – hinsichtlich Unternehmensgröße, Digitalisierungsgrad, Kundenfokussierung (B2B vs. B2C) sowie strategischem Mindset der Geschäftsleitung – stellt keine Einschränkung der Ergebnisse dar, sondern spiegelt die tatsächliche Komplexität des Untersuchungsfeldes wider. Die bewusst branchenübergreifende Stichprobenauswahl mit 39 Expert*innen aus Industrie, Handel, Dienstleistung, E-Commerce, Energieversorgung und Wissenschaft war darauf ausgerichtet, genau diese Heterogenität abzubilden und die Übertragbarkeit des entwickelten Frameworks auf unterschiedliche KMU-Kontexte zu gewährleisten. Dass bestimmte KMU-Typen – etwa kleinste Unternehmen, stark traditionsorientierte Familienbetriebe oder Unternehmen mit minimaler IT-Infrastruktur – in der Stichprobe weniger stark vertreten sind, verweist nicht auf eine methodische Schwäche, sondern auf einen produktiven Anschlusspunkt für zukünftige Forschung, die diese Segmente gezielt in den Blick nehmen kann.

Die kritische Reflexion dieser Herausforderungen macht die Grenzen und die Reichweite der Forschungsergebnisse transparent und unterstreicht zugleich die methodische Sorgfalt, mit der das vorliegende Framework entwickelt wurde. Nachdem das methodische Vorgehen in seinen einzelnen Phasen dargelegt und kritisch reflektiert wurde, richtet sich der Fokus nun auf die Ergebnisdarstellung. Das folgende fünfte Kapitel präsentiert das entwickelte Implementierungsframework und zeigt dessen Anwendungspotenzial für den deutschen Mittelstand systematisch auf.

5 ERGEBNISSE DER EMPIRISCHEN UNTERSUCHUNG UND ENTWICKLUNG DES IMPLEMENTIERUNGSFRAMEWORKS

5.1 Systematik der Ergebnisdarstellung und Frameworkentwicklung

Das fünfte Kapitel bildet den Kern der Forschungsarbeit und widmet sich der Darstellung der Forschungsergebnisse. Zu diesem Zweck ist die Gliederung des Kapitels so konzipiert, dass sie die Ergebnisse des mehrphasigen Forschungsprozesses transparent und nachvollziehbar darstellt.

Zunächst werden in Kapitel 5.2 die zentralen Erkenntnisse aus den Expert*inneninterviews und der Dokumentenanalyse präsentiert. Um die Komplexität des Implementierungsprozesses strukturiert abzubilden, werden die Ergebnisse in zwei übergeordnete Bereiche unterteilt: die prozessbeschreibenden Kategorien (Kapitel 5.2.1) und die prozessbegleitenden Kategorien (Kapitel 5.2.2). Während die prozessbeschreibenden Kategorien die chronologischen Phasen und konkreten Handlungsschritte der Implementierung abbilden, umfassen die prozessbegleitenden Kategorien übergeordnete Aspekte wie strategische Entscheidungen, organisatorische Rahmenbedingungen und technologische Grundlagen, die den gesamten Prozess beeinflussen. Aufbauend auf diesen Erkenntnissen wird in Kapitel 5.3 der Erstentwurf des Implementierungsframeworks vorgestellt. Dieser synthetisiert die zuvor identifizierten Kategorien und überführt sie in ein strukturiertes, prozessorientiertes Framework, dessen Konzeption sich an den Prinzipien des DSR orientiert. Es wird somit als Gestaltungsartefakt verstanden, das eine Brücke zwischen wissenschaftlicher Theorie und unternehmerischer Praxis schlägt, um der Implementierung generativer KI im deutschen Mittelstand wirksam zu begegnen. Im darauffolgenden Kapitel 5.4 werden die Ergebnisse der Validierungsphase präsentiert. Der in Kapitel 5.3 vorgestellte Erstentwurf wird in einer zweiten Erhebungsrunde erneut Expert*innen zur kritischen Prüfung und Kommentierung vorgelegt. Die aus diesen Validierungsgesprächen gewonnenen Erkenntnisse werden systematisch ausgewertet und dienen der Weiterentwicklung und Präzisierung des Erstentwurfes. Abschließend wird in Kapitel 5.5 das weiterentwickelte Implementierungsframework vorgestellt und anhand eines Anwendungsbeispiels aus dem Marketingprozess demonstriert.

Das nachfolgende Kapitel legt nun das Fundament für die Entwicklung dieses Frameworks. Es werden die Ergebnisse der Expert*inneninterviews und der Dokumentenanalyse detailliert dargestellt, beginnend mit den prozessbeschreibenden Kategorien.

5.2 Ergebnisse der Expert*inneninterviews und Dokumentenanalyse

5.2.1 Prozessbeschreibende Kategorien

5.2.1.1 Problemidentifikation und Kontextanalyse (PROB-IMP)

Aus der Auswertung der Expert*inneninterviews sowie der Podcastfolgen im Hinblick auf die prozessbeschreibenden Kategorien resultiert ein idealtypisches Vorgehensmodell, das in fünf aufeinanderfolgende Phasen gegliedert ist. Diese orientieren sich an den induktiv gebildeten Kategorien und fassen die synthetisierten Aussagen aus beiden Erhebungsinstrumenten zusammen. Sie bilden den chronologischen Ablauf eines Implementierungsprojekts ab und werden in den nachfolgenden Kapiteln detailliert beschrieben.

Die Ergebnisse¹⁷ der Phase „Problemidentifikation und Kontextanalyse“ verdeutlichen, dass bestehende Herausforderungen, Optimierungspotenziale und Zielbilder von Unternehmen methodisch strukturiert und analysiert werden. Dabei greifen sie auf bewährte Methoden wie Design Thinking, Open Spaces oder Stakeholder-Interviews zurück, um ein umfassendes Verständnis der Ausgangslage zu gewinnen. Ergänzend werden technische Visualisierungen wie Flowcharts, Prozesslandkarten oder Mindmaps eingesetzt, um Prozesse, Datenflüsse und Abhängigkeiten transparent darzustellen. Die Phase erweist sich dabei als konsequent problemzentriert und nicht primär technologiegetrieben. Für die Unternehmen steht die Frage im Vordergrund, ob und wie generative KI einen echten Mehrwert für den jeweiligen Anwendungsfall bieten kann. Die Technologie wird dabei auf zweierlei Weise integriert: Einerseits wird sie als potenzielle Lösung für identifizierte Probleme in Betracht gezogen, andererseits dient sie bereits in dieser frühen Phase als Werkzeug zur Unterstützung kreativer und analytischer Denkprozesse. Eine anschließende Auswahl und Priorisierung von Anwendungsfällen erfolgt entlang klar definierter Kriterien. Besonders hervorgehoben werden die erwartete Wirksamkeit der Lösung, der zu erwartende Umsetzungsaufwand, die strategische Passung zur Gesamtvision des Unternehmens sowie das Potenzial für organisationsweite Signalwirkung, beispielsweise durch die Identifikation von Pilotprojekten.

Zur systematischen Sammlung und Bewertung von Ideen etablieren Unternehmen häufig interne Mechanismen wie Task Forces, Vorschlagsplattformen oder unternehmensweite Pitch-Formate. Darüber hinaus offenbart sich der iterative Charakter des Prozesses: Die

¹⁷ Die dargestellten Ergebnisse stellen eine thematische Synthese der Expert*inneninterviews dar. Aus Gründen der Lesbarkeit wird auf Einzelreferenzen in den Kapiteln 5.2.1.1 bis 5.2.1.5 verzichtet; die Belegstellen sind dem Kategoriensystem in Anhang F zu entnehmen.

Phase der Problemidentifikation und Kontextanalyse wird nicht als einmaliger Schritt verstanden, sondern als kontinuierliche, strategisch eingebettete Ressource. Sollten sich im weiteren Verlauf technische oder organisatorische Hinderungsgründe ergeben, wird diese Phase erneut initiiert. Eine solche Schleifenlogik ermöglicht ein flexibles Reagieren auf veränderte Rahmenbedingungen und trägt zu tragfähigen Entscheidungen unter Unsicherheit bei. Die Verankerung der Ideenfindung als dauerhafte strategische Ressource wird durch intern geschaffene Strukturen wie Center of AI, Projektportfolios oder interne Kanäle unterstrichen.

5.2.1.2 Konzeptionierung und Planung (KONZ-IMP)

Die Konzeptionierungs- und Planungsphase beginnt idealtypisch mit einer detaillierten Analyse der bestehenden Hardware-, Software-, Daten- und Organisationsstruktur. Diese Bestandsaufnahme zielt darauf ab, Kompatibilitäten, Erweiterungsmöglichkeiten und notwendige Anpassungen zu identifizieren. Parallel dazu erfolgt die weitere Spezifizierung und Bewertung der in der Vor-Phase identifizierten Anwendungsfälle hinsichtlich ihres Mehrwerts für das Unternehmen.

Ein prägendes Merkmal der Konzeptionierungsphase ist die Priorisierung potenzieller Anwendungsfälle, welche anhand klar definierter Kriterien wie technische Machbarkeit, wirtschaftlicher Nutzen, Dringlichkeit und regulatorische Anforderungen erfolgt. Um eine fundierte Auswahl zu gewährleisten, greifen Unternehmen hierfür auf strukturierte Bewertungsmethoden oder Entscheidungsgremien zurück. Inhaltlich erstreckt sich die Phase auf technische Aspekte – etwa die Auswahl von Hardware und Softwarearchitektur – sowie auf übergreifende Governance-Themen wie Datenschutz und Compliance. Diese thematische Breite spiegelt sich in einer interdisziplinären Zusammenarbeit wider, in die neben der IT-Abteilung auch Fachbereiche, Rechtsabteilungen, Datenschutzverantwortliche und das Management aktiv eingebunden sind. Hierdurch wird sichergestellt, dass technische, rechtliche und organisatorische Belange gleichermaßen Berücksichtigung finden. Zusätzlich wird ein organisationaler Lernprozess angestoßen, um über Schulungen, KI-Richtlinien oder Pilotprojekte Wissen und Akzeptanz im Unternehmen zu fördern. Ebenso erweist sich die frühe Berücksichtigung von Rahmenbedingungen wie der Stakeholder-Anzahl, der Art des Anwendungsfalls sowie der rechtlichen Einstufung als wesentliche Komponente. Eine solche vorausschauende Planung schafft Klarheit und minimiert spätere Implementierungshürden.

5.2.1.3 Prototyping und Pilotierung (PROT-IMP)

Die Entwicklung eines ersten funktionsfähigen Prototyps oder MVP markiert den Einstieg in die Prototyping- und Pilotierungsphase. Hiermit werden die technische Umsetzbarkeit und der organisatorische Nutzen der KI-Anwendung frühzeitig überprüft. Der Erfolg dieses Schrittes hängt maßgeblich von der Verfügbarkeit geeigneter, strukturierter und zugänglicher Daten ab. Fehlen diese, muss zunächst eine gezielte Datenaufbereitung erfolgen, bevor die technische Entwicklung beginnen kann.

Pilotprojekte werden bewusst in einem kleinen, risikoarmen Rahmen realisiert. Der Fokus liegt meist auf spezifischen Zielgruppen oder Fachbereichen, die als besonders relevant oder experimentierfreudig gelten. Erste Testszenarien werden sowohl mit internen als auch externen Pilotgruppen durchgeführt. Methoden wie A/B-Tests kommen hierbei zum Einsatz, um die Wirksamkeit der KI-Anwendung unter realen Bedingungen zu prüfen. Das Feedback der Nutzer*innen spielt eine entscheidende Rolle für die Weiterentwicklung des Prototyps und wird in iterativen Schleifen systematisch zur Optimierung genutzt. In frühen Entwicklungsphasen wird gezielt auf einfache Standardlösungen wie ChatGPT oder alternative KI-Anwendungen gesetzt, um erste Erkenntnisse über den Mehrwert eines Einsatzes zu gewinnen, ohne bereits komplexe technische Integrationen vorzunehmen. In weiterführenden Schritten werden die Prototypen technisch ausdifferenziert, etwa durch die Einbindung realer Datenquellen über APIs sowie die Bereitstellung auf spezifischen technischen Infrastrukturen wie Cloud oder lokalen Systemen. Sobald ein Prototyp in realen Tests erfolgreich validiert wurde, beginnt die Überführung in den produktiven Betrieb. Hierzu wird ein strukturierter Qualitätssicherungsprozess empfohlen, der das System weiterentwickelt und optimiert. Die Beteiligung der Nutzer*innen wird in dieser Phase kontinuierlich fortgeführt.

5.2.1.4 Integration und Rollout (INT-IMP)

Der Übergang in die Integrations- und Rolloutphase erfolgt typischerweise nach den initialen Tests des Systems in einer kleinen, ausgewählten Pilotgruppe. Daraufhin erfolgt eine sukzessive Ausweitung auf eine breitere Gruppe von Nutzer*innen, beispielsweise durch die Veröffentlichung einer Beta-Version oder die Einbindung weiterer Fachabteilungen. Dieses Vorgehen dient dazu, frühzeitig Rückmeldungen zu sammeln, notwendige Anpassungen vorzunehmen und Implementierungsrisiken zu minimieren.

Die technische Integration erfolgt durch die Anbindung an bestehende IT-Systeme und Infrastrukturen, wie Produktinformations-Management-Systeme (PIM), Content-Management-

Systeme oder Datenmanagementlösungen. Parallel dazu werden organisatorische Maßnahmen umgesetzt, insbesondere in Form von Schulungen, Trainings und begleitenden Kommunikationsmaßnahmen. Ein weiteres zentrales Element für den Erfolg des Rollouts ist die kommunikative Begleitung. Klare Informationen und transparente Kommunikation schaffen Orientierung und Vertrauen bei den Mitarbeitenden, insbesondere in der Phase der Überführung in den operativen Betrieb. Ferner wird betont, dass ein grundlegendes Verständnis für die eingesetzte Technologie und deren Wirkungsweise aufgebaut werden muss. Die Bewusstseinsbildung auf Seiten der Nutzer*innen wird als Voraussetzung für eine tragfähige Implementierung angesehen.

Eine erste Überprüfung erfolgt sowohl technisch als auch aus Sicht der Nutzer*innen, beispielsweise über strukturierte Feedbackmechanismen. Dadurch wird sichergestellt, dass sowohl die technische Funktionalität als auch die praktische Anwendbarkeit gegeben sind. In der Praxis zeigt sich, dass sich verfügbare KI-Anwendungen in einem hohen Tempo entwickeln. Dies erfordert von den Unternehmen flexible und adaptive Strategien bei der Integration, um mit technologischen Weiterentwicklungen umgehen zu können. Die gezielte systemische Einbettung in bestehende Geschäftsprozesse gilt dabei als zentraler Erfolgsfaktor.

5.2.1.5 Evaluation und Skalierung (EVA-IMP)

Das Zusammenwirken von technischen, organisatorischen und wirtschaftlichen Aspekten ist für die letzte Phase der Evaluation und Skalierung entscheidend. Sie ist folglich nicht als einmaliger Abschluss zu verstehen, sondern als ein dynamischer Regelkreis, der fortlaufende Reflexion und strategische Entscheidungen ermöglicht. In diesem Prozess wird der Wertbeitrag der KI-Anwendung bewertet und die strategische Weiterentwicklung gesteuert.

Im Zentrum der Evaluation steht die systematische Überprüfung, ob die implementierte Lösung stabil funktioniert, im Alltag genutzt wird und die Erwartungen der Nutzer*innen sowie der Projektverantwortlichen erfüllt. Hierzu werden sowohl technische Kennzahlen – wie Systemperformance, Antwortgeschwindigkeit oder Verfügbarkeit – als auch qualitative Rückmeldungen aus der Nutzungspraxis herangezogen. Die Kombination dieser quantitativen und qualitativen Daten schafft eine umfassende, datenbasierte Entscheidungsgrundlage für die weitere Entwicklung. Nach einer initial erfolgreichen Umsetzung wird ein strukturierter Monitoring-Prozess etabliert. Dieser überprüft kontinuierlich die Stabilität, Nutzungsintensität und organisationale Anschlussfähigkeit der Lösung. Performance-Dashboards und strukturierte Feedbackschleifen werden genutzt, um Erfahrungswissen zu dokumentieren

und gezielt in die Weiterentwicklung einzubringen. Die Evaluation umfasst dabei nicht nur die technische Funktionalität, sondern auch die Akzeptanz und den tatsächlichen Mehrwert im Arbeitsalltag.

Die Skalierung erfolgt in der Regel inkrementell durch die sukzessive Einbindung weiterer Unternehmensbereiche oder Personengruppen. Unter Berücksichtigung von Stabilität, Nutzungsintensität und organisationaler Passung erfolgt die Übertragung erfolgreicher Prototypen in andere Bereiche. Projekte werden nicht als abgeschlossene Einheiten, sondern als dynamische Systeme begriffen, die sich entlang von Nutzungserfahrungen, Kennzahlen und Feedback fortlaufend weiterentwickeln. Ein weiteres zentrales Element der Evaluation und Skalierung ist die ausführliche Dokumentation der Ergebnisse und Erfahrungen. Demnach sichern Abschlussberichte, Konzeptpapiere und Prozessvisualisierungen Transparenz, Nachvollziehbarkeit und Transferierbarkeit der Erkenntnisse. Diese Dokumente enthalten neben dem aktuellen Projektstand auch Empfehlungen für nächste Schritte und dienen als strategische Ressource für zukünftige Vorhaben.

5.2.2 Prozessbegleitende Kategorien

5.2.2.1 Implementierungsstrategie und übergeordnete Zielsetzungen (STRAT)

Nachdem die Ergebnisse der Phasen chronologisch vorgestellt wurden, widmen sich die nachfolgenden Kapitel den prozessbegleitenden Kategorien. Diese umfassen übergeordnete Aspekte, die nicht an eine einzelne Phase gebunden sind, sondern den gesamten Implementierungsprozess kontinuierlich beeinflussen. Die Analyse der Expert*inneninterviews hat vier zentrale Kategorien ergeben, deren Darstellung mit der Implementierungsstrategie und strategischen Zielsetzung beginnt.

Die Entwicklung und Umsetzung von Implementierungsstrategien stellt einen hochdynamischen und vielschichtigen Prozess dar. Anstelle eines einheitlichen Masterplans zeigen die Ergebnisse¹⁸, dass die strategische Steuerung auf einem komplexen Zusammenspiel aus Zielarchitekturen, Steuerungslogiken und kulturellen Voraussetzungen beruht. Im Zentrum steht die Erkenntnis, dass Strategiearbeit im Kontext generativer KI nicht als statischer, langfristig festgelegter Plan zu verstehen ist, sondern als ein lebendiges, iteratives Steuerungs-

¹⁸ Die dargestellten Ergebnisse stellen eine thematische Synthese der Expert*inneninterviews dar. Aus Gründen der Lesbarkeit wird auf Einzelreferenzen in den Kapiteln 5.2.2.1 bis 5.2.2.4 verzichtet; die Belegstellen sind dem Kategoriensystem in Anhang F zu entnehmen.

system, das kontinuierlich an neue operative, technologische und organisationale Entwicklungen angepasst wird. Zudem verdeutlicht die Analyse, dass Unternehmen einem Implementierungsvorhaben zumeist keine KI-Strategie zugrunde legen. Diejenigen, die eine KI-Strategie vorweisen können begreifen diese jedoch als dynamischen sowie zyklischen Prozess, der Erfahrungen integriert und sich an veränderte Bedingungen anpasst. Übergeordnete Zielsetzungen werden inhaltlich breit gefasst und dienen primär der Richtungsgebung. Sie umfassen ökonomische, technologische, kulturelle und strukturelle Dimensionen und sind so ausgestaltet, dass sie verschiedene Umsetzungspfade ermöglichen. Ziele fungieren dabei als flexibel auslegbare Leitplanken, die eine adaptiv gesteuerte Implementierung unterstützen. Demnach zeichnen sich effektive KI-Strategien durch die koordinierte Verknüpfung von zentralen Steuerungselementen und dezentraler Beteiligung aus. Top-down-Elemente wie die Festlegung und Allokation von Ressourcen, die Formulierung von Visionen und die Etablierung von Governance-Strukturen werden mit Bottom-up-Prozessen wie der Identifikation von Anwendungsfällen und dem Engagement der Mitarbeitenden verknüpft. Diese Verschränkung ermöglicht es, strategische Kohärenz mit operativer Anschlussfähigkeit zu verbinden und fördert zugleich Innovationsfähigkeit und Akzeptanz.

Als weiteres Ergebnis ist die kulturelle Verankerung als strategische Notwendigkeit zu nennen. Kultur wird nicht als begleitender Faktor, sondern als integraler Bestandteil strategischer Wirksamkeit verstanden. Der Wandel hin zu einer KI-affinen Kultur, die durch Lernbereitschaft, Offenheit für Experimente und partizipative Strukturen geprägt ist, wird als elementar für die erfolgreiche Umsetzung strategischer Vorhaben angesehen. Der Aufbau eines solchen Mindsets erfordert gezielte Change-Maßnahmen und eine langfristige Veränderungsarchitektur. Unternehmen setzen hierzu eine Vielzahl von Modellen, Methoden und Frameworks ein, die jeweils kontextsensitiv kombiniert werden. Die Auswahl erfolgt nicht standardisiert, sondern anhand von Reifegrad, Zielsetzung und Anwendungsfeld. Die Reflexion über Modellwahl und -nutzung wird dabei selbst Teil strategischer Kompetenzentwicklung und stellt sicher, dass Instrumente nicht formalistisch, sondern praxiswirksam eingesetzt werden.

5.2.2.2 Technologieeinsatz und Systemintegration (TECH)

Hinsichtlich der technologischen Grundlagen lässt sich keine Dominanz eines einheitlichen Standards oder einer universellen Systemarchitektur feststellen. Stattdessen zeigt sich, dass

Unternehmen unterschiedliche, jedoch strukturiert angelegte Ansätze verfolgen, um technologische Flexibilität, regulatorische Steuerbarkeit und operative Anschlussfähigkeit zu verbinden. Diese Vielfalt der Ansätze unterstreicht die Erkenntnis, dass Technologieentscheidungen nicht isoliert getroffen werden, sondern stets im Zusammenspiel mit organisatorischen, regulatorischen und kulturellen Rahmenbedingungen stehen.

Im Bereich der Systemarchitektur zeigt sich eine deutliche Tendenz hin zu modularen und offenen Ansätzen. Diese hybriden Infrastrukturen kombinieren Cloud-basierte Dienste, Self-Hosting-Optionen und Middleware-Lösungen, um technologische Flexibilität und Unabhängigkeit von einzelnen Anbietern zu gewährleisten. Die Auswahl konkreter Basistechnologien erfolgt dabei überwiegend anwendungsbezogen und ist abhängig vom jeweiligen Einsatzzweck, den datenschutzrechtlichen Anforderungen, der vorhandenen Hardware-, Software-, Daten- und Organisationsstruktur sowie der personellen Ressourcenausstattung. Dabei ist die Toolauswahl dynamisch und durch iterative Test- und Prototypingphasen geprägt. Strategische Präferenzen für bestimmte Anbieter, zum Beispiel aus Europa oder dem Open-Source-Bereich, spielen eine ergänzende, jedoch nicht primär entscheidende Rolle. Ein zentrales Muster in der technologischen Umsetzung ist die Integration generativer KI in bestehende Unternehmenssysteme über APIs. Zugleich zeigt sich, dass Integration nicht ausschließlich eine technische Herausforderung darstellt, sondern auch organisatorisch flankiert werden muss – etwa durch Prozessanpassungen, Kompetenzaufbau und begleitende Kommunikationsmaßnahmen. KI-Anwendungen werden zunehmend auch implizit über Standardsoftware genutzt, was deren Verbreitung fördert, jedoch neue Anforderungen an Kontrolle und Transparenz mit sich bringt.

5.2.2.3 Erfolgsmessung und Bewertungskriterien (EVAL)

Anstelle einer Fokussierung auf eindimensionale Kennzahlen, wird bei der Erfolgsmessung ein multidimensionaler Ansatz verfolgt. Sie ziehen eine Vielzahl unterschiedlicher Bewertungskriterien heran, die technologische, ökonomische, prozessuale, nutzerbezogene sowie strategische Aspekte abdecken. Die Erfolgsmessung dient somit nicht nur der retrospektiven Kontrolle, sondern etabliert sich vielmehr als integraler Bestandteil der strategischen Steuerung und der organisationalen Lernprozesse.

Die Bewertungspraxis der Unternehmen ist durch die Etablierung einer multidimensionalen Architektur geprägt. Anstatt auf einzelne KPIs zu vertrauen, werden technische Leistungskennzahlen, ökonomische Erfolgsgrößen, prozessuale Effizienzindikatoren sowie subjektive

Einschätzungen der Nutzer*innen systematisch kombiniert. Diese multiperspektivische Herangehensweise ermöglicht eine differenzierte Einschätzung des Erfolgs generativer KI, die sowohl funktionale Effekte als auch organisationale und soziale Wirkungen berücksichtigt. Die Auswahl der Bewertungskriterien ist somit kontextualisiert und anwendungsfeldspezifisch ausgelegt. Je nach Use Case, fachlichem Einsatzbereich und strategischer Zielsetzung variieren die eingesetzten KPIs erheblich. Während in Marketingkontexten beispielsweise Metriken wie der Return on Advertising Spend oder die Conversion Rate im Vordergrund stehen, dominieren in Servicebereichen Kennzahlen wie Fallbearbeitungszeit oder Kundenzufriedenheit.

Schließlich kombinieren Unternehmen quantitative und qualitative Bewertungsverfahren, indem Kennzahlen wie Zeitersparnis, Anzahl der Nutzenden oder Fehlerreduktion mit qualitativen Einschätzungen wie wahrgenommener Entlastung, Technologieakzeptanz oder Contentqualität verknüpft werden. Erfolgsmessung dient somit nicht nur der nachträglichen Bewertung, sondern auch der Legitimation zukünftiger Investitionen, der Kommunikation mit Stakeholdern und der gezielten Steuerung von Veränderungsprozessen. Ökonomische Indikatoren wie ROI oder Einsparpotenziale werden als Entscheidungsgrundlage für Skalierung oder Weiterentwicklung genutzt. Somit erfolgt die Anwendung von Bewertungskriterien nicht statisch, sondern wird im Projektverlauf immer wieder angepasst. Unternehmen entwickeln flexible Bewertungsraster, führen A/B-Tests durch, implementieren kontinuierliche Feedbackschleifen und reagieren auf neue technische, organisatorische oder marktbezogene Entwicklungen.

5.2.2.4 Zukünftige Entwicklungen und KI-Roadmap (FUT)

Die befragten Unternehmen nutzen KI-Roadmaps als zentrales Steuerungsinstrument ihrer Implementierungsprozesse. Diese Roadmaps orientieren sich an strategischen, technologischen und kulturellen Bezugspunkten, die den Rahmen für zukünftige Entwicklungsschritte bilden. Sie sind dabei nicht als lineare Zeitpläne zu verstehen, sondern fungieren als flexible strategische Reflexions- und Handlungsrahmen, die kontinuierliches Lernen und organisationale Weiterentwicklung ermöglichen.

In ihrer Funktion erweist sich eine KI-Roadmap als integratives Steuerungsinstrument für eine adaptive Organisationsentwicklung. Der Einstieg in die Roadmap-Entwicklung erfolgt typischerweise über eine strukturierte Standortbestimmung, in der Digitalisierungsgrad, Kompetenzen und organisationale Offenheit gegenüber KI analysiert werden. Im weiteren

Verlauf werden Pilotprojekte genutzt, um nicht nur die technologische Machbarkeit, sondern auch die kulturelle Anschlussfähigkeit zu validieren. Sie dienen dabei weniger als Zielkatalog, sondern vielmehr als Rahmenwerk, das übergeordnete Zielsetzungen mit operativer Flexibilität verbindet und sich durch zyklische Anpassung an Veränderungen in Technologie, Markt und Organisation kontinuierlich weiterentwickelt.

Die Ausgestaltung der KI-Roadmap ist durch externe technologische Entwicklungen geprägt. Hierbei markieren der Einsatz autonom agierender Agentensysteme, multimodaler Schnittstellen und die Etablierung systemübergreifender KI-Anwendungen exemplarische Innovationslinien. Diese technologischen Trends erfordern nicht nur Integrationskompetenz, sondern auch eine Umstrukturierung der Rollenverteilung zwischen Mensch und Maschine. Generative KI wird in Unternehmen zunehmend nicht mehr nur als einzelne Anwendung betrachtet, sondern entwickelt sich zu einem integralen Bestandteil der gesamten digitalen Infrastruktur. Befragte Unternehmen reagieren darauf, indem sie gezielt Steuerungsmechanismen für den KI-Einsatz etablieren, Datenstrukturen schaffen, die einen systemübergreifenden Informationsaustausch ermöglichen, und Anbieter auswählen, deren Lösungen sich nahtlos in bestehende Systeme integrieren lassen.

Die erfolgreiche Umsetzung einer unternehmensweiten KI-Strategie erfordert weit mehr als reine Technologieinvestitionen. Vielmehr verändert der Einsatz generativer KI die Arbeitsweise der Unternehmen grundlegend: Im Mittelpunkt stehen nun Kompetenzen wie die kritische Bewertung von KI-Ergebnissen, die flexible Anpassung an neue Anforderungen und der verantwortungsvolle Umgang mit algorithmischen Systemen. Diese Fähigkeiten sind entscheidend, um den nachhaltigen Nutzen von KI im Unternehmenskontext zu sichern. Unternehmen reagieren darauf mit umfassenden Weiterbildungsmaßnahmen, der Etablierung neuer Rollenprofile und der Integration partizipativer Formate. Die Förderung metakognitiver Fähigkeiten wird dabei ebenso wichtig empfunden wie technisches Know-how, sodass KI-Roadmaps als Instrumente ganzheitlicher Kompetenzentwicklung bezeichnet werden.

Nach der Darstellung der prozessbeschreibenden und prozessbegleitenden Kategorien richtet sich der Fokus des nachfolgenden Kapitels auf die empirisch belegten Dissenspunkte und kontroverse Ergebnisse.

5.2.3 Dissenspunkte und kontroverse Ergebnisse

Die Entwicklung eines robusten Implementierungsframeworks erfordert nicht nur die Beschreibung des idealtypischen Prozesses, sondern auch eine gezielte Auseinandersetzung mit

den zentralen Spannungsfeldern. Demzufolge steht nicht die Beschreibung von Best Practices oder Gemeinsamkeiten im Mittelpunkt, sondern die systematische Analyse von Kontroversen, Zielkonflikten und divergierenden Steuerungslogiken, die als empirische Grundlage der nachfolgenden Validierungsphase dienen. Dabei zeigt sich, dass die prozessbeschreibenden Kategorien einen hohen Konsens aufweisen, sodass eine vertiefende Auseinandersetzung an dieser Stelle nicht erforderlich ist. Innerhalb der prozessbegleitenden Kategorien lassen sich hingegen Kontroversen identifizieren. Die dort bestehenden unterschiedlichen Sichtweisen spiegeln die Vielschichtigkeit organisationaler Realitäten und die Heterogenität der Steuerungslogiken wider.

Die bereits festgestellte hohe Dynamik und Kontextabhängigkeit des Implementierungsprozesses manifestiert sich im Datenmaterial in einer wesentlichen Kontroverse: dem Spannungsfeld zwischen zentral gesteuerten Implementierungsstrategien und dezentral initiierten Praxisprojekten. Während einige Expert*innen klare Vorgaben, zentrale Ressourcensteuerung und formale Governance-Strukturen als Voraussetzung für Skalierbarkeit und Sicherheit betrachten, plädieren andere für die Förderung dezentraler, informell initiiertes Pilotprojekte, die nah an konkreten Bedarfen der Nutzer*innen agieren. Weiterhin divergieren die Positionen zwischen einer technologieorientierten Sichtweise, die technische Effizienz und Systemoptimierung betont, und einer sozio-organisationalen Perspektive, die Akzeptanz, Partizipation und Lernbereitschaft in den Vordergrund stellt. Auch die Frage nach der Rolle von Stakeholdern – passive Adressaten versus aktive Mitgestalter – bleibt umstritten. Schließlich kontrastieren lineare, phasenorientierte Projektlogiken mit iterativ-adaptiven Vorgehensweisen.

Ein weiterer Dissens besteht zwischen zentral entwickelten KI-Strategien, die auf Kohärenz und Governance abzielen, und dezentralen, partizipativen Prozessen, die Praxisnähe und organisationale Resonanz betonen. Während einige Unternehmen eine am Use Case zentrierte, pragmatische Strategie verfolgen, setzen andere auf einen kulturgetriebenen Ansatz, bei dem Haltung und organisationales Lernen im Vordergrund stehen. Uneinigkeit besteht zudem hinsichtlich der Formalisierung: Formalisierte Strategiearchitekturen mit klaren Zielsystemen stehen flexiblen, adaptiven Prozessen gegenüber. Auch der Einsatz standardisierter Modelle und Frameworks versus situativer Methodenintegration ist umstritten. Schließlich variiert das Verständnis strategischer Zielklarheit – von frühzeitig festgelegten Zielen bis hin zu dynamisch verhandelten Entwicklungspfaden.

Der Einsatz von Basistechnologien ist durch Heterogenität und Flexibilität geprägt. Die Dissenspunkte betreffen insbesondere die grundlegende Differenz zwischen der Nutzung ganzheitlicher und spezialisierter KI-Anwendungen. Während ganzheitliche KI-Anwendungen (z.B. Langdock) einen schnellen Rollout und geringen Wartungsaufwand versprechen, legen spezialisierte KI-Anwendungen (z.B. HeyGen) Wert auf einen klar abgegrenzten Anwendungsbereich und geringe Einstiegshürden. Uneinigkeit herrscht auch hinsichtlich der Tool-Landschaft: Standardisierte, ganzheitliche Komplettlösungen stehen einem dynamischen, situativ kombinierten Tool-Mix gegenüber. Die Wahl zwischen cloudbasierter Infrastruktur und Self-Hosting/Edge-Lösungen reflektiert zudem unterschiedliche Prioritäten bezüglich Datenschutz und Systemkontrolle. Unterschiedliche Auffassungen bestehen ebenso bei der Integrationstiefe in bestehende Systeme wie auch über die Gewichtung technikzentrierter versus soziotechnischer Perspektiven.

Die Erfolgsmessung ist durch eine Kontroverse zwischen der Art der Effizienzmetriken und dessen Wirkungsindikatoren geprägt. Während einige Unternehmen individuell angepasste KPIs pro Use Case etablieren, streben andere nach unternehmensweiten Standards. Hierbei wird der Zeitpunkt und Zweck der Evaluation kontrovers begründet: Während der Erfolg häufig retrospektiv gemessen wird, erfolgt die Evaluation in anderen Fällen begleitend und formativ, um den laufenden Prozess kontinuierlich zu beobachten, Rückmeldungen zu geben und dessen Steuerung sowie Optimierung zu unterstützen. Technikorientierte Output-Kontrolle konkurriert mit nutzerzentrierter Wirkungsanalyse. Schließlich variiert der Grad der Komplexität von monodimensionalen Steuerungskennzahlen bis hin zu multidimensionalen Bewertungssystemen.

Im Zuge der KI-Roadmaps zeigt sich ein Dissens zwischen linearer Zielplanung und einer adaptiven, iterativ angelegten Roadmap-Logik. Während einige Organisationen auf langfristige Zielsysteme und Meilensteinplanung setzen, bevorzugen andere flexible, rückgekoppelte Planungspfade. Unterschiedliche Ausgangsperspektiven – technologiegetriebene versus kulturgetriebene Roadmaps – prägen die strategische Ausrichtung. Standardisierte Einstiegsszenarien konkurrieren mit kontextspezifischen Entwicklungspfaden. Kontrovers diskutiert wird zudem das Verhältnis von technologischer Automatisierung und menschlicher Supervision sowie die Frage, ob bestehende Rollenprofile stabilisiert oder neue Kompetenzmodelle geschaffen werden sollen.

Die Darlegung der Dissenspunkte und Kontroversen hat die zentralen Spannungsfelder im Implementierungsprozess offengelegt. Um aus diesen analytischen Erkenntnissen ein konstruktives und anwendungsorientiertes Framework entwickeln zu können, müssen nun die praxisrelevanten Implikationen aus den gesamten empirischen Daten synthetisiert werden. Das folgende Kapitel widmet sich daher der systematischen Ableitung dieser Implikationen und schlägt die Brücke zur eigentlichen Framework-Entwicklung.

5.2.4 Praxisrelevante Implikationen und Brücke zur Framework-Entwicklung

Die Untersuchung zeigt, dass die erfolgreiche Implementierung generativer KI von einer Vielzahl ineinandergreifender Faktoren abhängt. Für jede der prozessbeschreibenden sowie prozessbegleitenden Kategorien lassen sich spezifische praxisrelevante Implikationen ableiten, die unmittelbar in die Entwicklung des anwendungsorientierten Frameworks einfließen sollen. Eine zusammenfassende Darstellung kann Tabelle 13 entnommen werden.

Tabelle 13: Implikationen und Anforderungen an das Implementierungsframework

Kategorie	Praxisrelevante Implikation	Anforderung an das zu entwickelnde Framework
Implementierungsprozess (IMP, prozessbeschreibende Kategorie)	Die Implementierung ist kein linearer Ablauf, sondern ein dynamischer, iterativer Zyklus, der kontinuierliches Lernen und die Einbindung von Stakeholdern erfordert.	Das Framework muss als zyklisches, lernorientiertes Prozessmodell konzipiert sein, das explizite Feedback-Schleifen zwischen den Phasen ermöglicht.
Strategische Steuerung (STRAT, prozessbegleitende Kategorie)	Starre Masterpläne sind ungeeignet. Erfolgreich sind adaptive, hybride Ansätze, die zentrale Vorgaben mit dezentralen Innovationsimpulsen und einer KI-affinen Kultur verbinden.	Das Framework muss eine hybride Steuerungslogik unterstützen und darf keine rigide, von oben nach unten gerichtete Planungsstruktur vorschreiben.
Technologieeinsatz (TECH, prozessbegleitende Kategorie)	Die Technologieauswahl ist kontextabhängig. Modulare, offene Architekturen werden bevorzugt, um Flexibilität, Datenschutz und Systemkontrolle zu gewährleisten.	Das Framework muss technologieoffen sein und die Auswahl modularer, an den spezifischen Anwendungsfall angepasster Systemarchitekturen ermöglichen.
Erfolgsmessung (EVAL, prozessbegleitende Kategorie)	Die Erfolgsmessung ist multidimensional (technisch, ökonomisch, prozessual, nutzerbezogen) und dient als kontinuierliches Steuerungsinstrument, nicht nur zur nachträglichen Kontrolle.	Das Framework muss eine mehrdimensionale und prozessbegleitende Evaluation als integralen Bestandteil jeder Phase verankern.
Zukünftige Entwicklung (FUT, prozessbegleitende Kategorie)	KI-Roadmaps sind keine starren Zeitpläne, sondern adaptive, strategische Leitlinien, die kontinuierlich an neue Anforderungen angepasst werden, um Kompetenzen und Rollen zu entwickeln.	Das Framework muss einen Mechanismus zur Erstellung und kontinuierlichen Adaption einer strategischen Roadmap beinhalten, der über den einzelnen Implementierungszyklus hinausgeht.

Quelle: Eigene Darstellung

Im Zuge des Implementierungsprozesses wird deutlich, dass Unternehmen von einem flexiblen, iterativen Vorgehen profitieren. Die Praxis zeigt, dass die Implementierung generativer KI nicht als linearer Ablauf, sondern als dynamischer Zyklus zu verstehen ist, in dem

Problemidentifikation, Konzeption, Prototyping, Integration und Evaluation immer wieder neu durchlaufen werden. Die kontinuierliche Einbindung relevanter Stakeholder und die Förderung einer offenen Lernkultur sind dabei entscheidend, um Akzeptanz und nachhaltigen Nutzen zu sichern. Interne Strukturen wie Kompetenzzentren oder Task Forces unterstützen diesen Prozess und ermöglichen es, auf Veränderungen im Unternehmensumfeld schnell zu reagieren.

Die strategische Steuerung erfordert es, klassische Masterpläne zugunsten adaptiver, hybrider Ansätze zu ersetzen. Unternehmen, die ihre KI-Strategie als lebendigen, anpassungsfähigen Prozess gestalten, können besser auf technologische und organisatorische Veränderungen eingehen. Dabei ist es entscheidend, sowohl zentrale Steuerungselemente als auch dezentrale Innovationsimpulse zu berücksichtigen. Die Entwicklung einer KI-affinen Unternehmenskultur, die Experimente und partizipative Prozesse fördert, bildet hierfür eine wesentliche Grundlage.

Im Kontext Technologie zeigt sich, dass die Auswahl und Integration von KI-Anwendungen vom jeweiligen Anwendungsfall und den spezifischen Rahmenbedingungen abhängt. Unternehmen setzen zunehmend auf modulare, offene Systemarchitekturen, die eine flexible Anpassung an neue Anforderungen ermöglichen. Die enge Verzahnung technischer und organisatorischer Maßnahmen – etwa durch einen gezielten Kompetenzaufbau und die Anpassung bestehender Prozesse – ist dabei ein zentraler Erfolgsfaktor. Datenschutz, Systemkontrolle und Unabhängigkeit von einzelnen Anbietern spielen bei der Technologieauswahl eine wichtige Rolle.

Die Erfolgsmessung generativer KI-Projekte ist in der Praxis durch eine Vielzahl unterschiedlicher Bewertungsansätze geprägt. Unternehmen kombinieren technische, wirtschaftliche, prozessuale und nutzerbezogene Kennzahlen, um den Erfolg ihrer Initiativen umfassend zu bewerten. Dabei wird deutlich, dass Erfolgsmessung nicht nur der nachträglichen Kontrolle dient, sondern auch als Steuerungsinstrument für die Weiterentwicklung und Anpassung von KI-Anwendungen genutzt wird. Flexible Bewertungsraster und kontinuierliche Feedbackschleifen unterstützen diesen Lernprozess.

Mit Blick auf zukünftige Entwicklungen wird die Bedeutung adaptiver KI-Roadmaps deutlich. Diese dienen nicht als starre Zeitpläne, sondern als strategische Leitlinien, die kontinuierlich an neue technologische, organisatorische und kulturelle Anforderungen angepasst

werden. Unternehmen nutzen Roadmaps, um Kompetenzen gezielt aufzubauen, Pilotprojekte zu steuern und neue Rollenprofile zu etablieren. Die Förderung von Weiterbildungsmaßnahmen und die Integration partizipativer Formate sind dabei ebenso wichtig wie die technische Weiterentwicklung.

Insgesamt zeigt sich, dass ein wirksames Implementierungsframework auf Flexibilität, Partizipation und kontinuierliches Lernen ausgerichtet sein muss. Die in den vorangegangenen Kapiteln herausgearbeiteten Implikationen zeigen auf, dass die Implementierung nicht durch starre Standardmodelle, sondern durch ein hohes Maß an Anpassungsfähigkeit, Iteration und Kontextsensitivität geprägt ist. Daraus ergibt sich die Notwendigkeit, ein Framework zu entwickeln, das diese empirisch identifizierten Anforderungen systematisch aufgreift und in eine strukturierte, praxisnahe Handlungsarchitektur überführt. Es muss die zyklische Prozesslogik, die Verschränkung strategischer und operativer Steuerungsmechanismen, die technologische Modularität, die multidimensionale Erfolgsmessung sowie die adaptive Roadmap-Logik integrativ abbilden.

Die Erkenntnisse dienen somit als konzeptionelle Bausteine für die Framework-Ableitung. Sie liefern die inhaltlichen und methodischen Leitplanken, entlang derer die Struktur und die Komponenten des Frameworks entwickelt werden. Im nachfolgenden Kapitel wird dieser Übergang systematisch vollzogen, indem die empirisch gewonnenen Kategorien und Implikationen in den Erstentwurf des Implementierungsframeworks überführt werden.

5.3 Ableitung Erstentwurf Implementierungsframework

5.3.1 Problemdefinition und Zielsetzung

Die Zielsetzungen, die dem Implementierungsframework zugrunde liegen, werden aus zwei Perspektiven hergeleitet. Aus theoretischer Sicht steht die Entwicklung eines kohärenten, wissenschaftlich fundierten Modells im Vordergrund, das empirische Erkenntnisse mit bestehenden theoretischen Ansätzen systematisch verknüpfen soll. Die Entwicklung und Validierung des Frameworks erfolgt dabei nach anerkannten wissenschaftlichen Gütekriterien, um Validität, Nachvollziehbarkeit und Transferierbarkeit zu gewährleisten. Aus praktischer Sicht soll das Framework als Orientierungsrahmen für die strategische Planung, operative Umsetzung und Evaluation von KI-Implementierungsprozessen dienen. Es soll Akzeptanz und organisationales Lernen fördern, Change-Management und Weiterbildungsmaßnahmen unterstützen und zur Entwicklung einer KI-affinen Unternehmenskultur beitragen. Die An-

passungsfähigkeit an verschiedene Unternehmensgrößen, Branchen und Kontexte soll gewährleistet sein, sodass das Framework als praxisnaher, anschlussfähiger und wissenschaftlich fundierter Orientierungsrahmen für den deutschen Mittelstand fungieren kann.

Aufbauend auf den empirischen Ergebnissen aus Kapitel 5.2 beginnt nun die systematische Ableitung des Implementierungsframeworks. Diese erfolgt unter Berücksichtigung der in Kapitel 4.3.3.2 festgelegten methodischen Schritte nach Hevner et al. (2004) und Jabareen (2009) (Abbildung 9). Dementsprechend repräsentieren die Kapitel 5.3.1 bis 5.3.3 die ersten drei und die Kapitel 5.4.1 sowie 5.4.2 die letzten beiden Schritte der Ableitungsmethodik.

Den Ausgangspunkt im ersten Schritt bildet die Definition der Problemstellung, die sich direkt aus den identifizierten Herausforderungen ergibt: Die Implementierung generativer KI im deutschen Mittelstand ist durch eine Vielzahl spezifischer Herausforderungen und struktureller Hemmnisse geprägt (Bartelt, 2024). Empirische Analysen verdeutlichen, dass ihr Einsatz bislang überwiegend in Form isolierter Einzellösungen erfolgt, die sich vornehmlich auf operative Aufgaben konzentrieren (Bartelt, 2024; Oldemeyer et al., 2024). Eine ganzheitliche, prozessorientierte Integration in sowohl operative als auch strategische Unternehmensprozesse bleibt hingegen vielfach aus. Infolgedessen werden Synergieeffekte und nachhaltige Wertschöpfungspotenziale nicht ausgeschöpft, sodass die Einführung häufig auf Pilotprojekte begrenzt bleibt und eine unternehmensweite Skalierung ausbleibt (Röser & Bartelt, 2024).

Ein zentrales Hemmnis stellt die Ressourcenknappheit mittelständischer Unternehmen dar. Begrenzte finanzielle, personelle und zeitliche Ressourcen führen dazu, dass das Tagesgeschäft regelmäßig Vorrang erhält und notwendige Investitionen in Infrastruktur, Schulung und Change-Management verzögert werden (Bartelt & Röser, 2024a). Hinzu treten erhebliche Wissenslücken und Defizite in der gezielten Weiterbildung sowohl auf Mitarbeitenden- als auch auf Managementebene. Das Top-Management agiert häufig reaktiv und unterschätzt die strategische Bedeutung generativer KI, was die Entwicklung klarer Visionen und nachhaltiger Strategien erheblich erschwert (Bartelt, 2024). Akzeptanzprobleme und Substitutionsängste – insbesondere die Sorge um Arbeitsplatzverluste sowie Unsicherheiten bezüglich der Passgenauigkeit KI-generierter Inhalte – wirken zusätzlich hemmend auf die Nutzung ein (Bartelt & Röser, 2024b).

Ergänzende Herausforderungen betreffen Fragen des Datenschutzes und der Datensicherheit. Die Nutzung von Drittanbieter-Technologien wirft Unsicherheiten hinsichtlich der Einhaltung gesetzlicher Vorgaben und der Kontrolle über sensible Unternehmensdaten auf (Bartelt, 2024). Zudem bleibt der konkrete Nutzen generativer KI, insbesondere im Hinblick auf Zielsetzungen und Erfolgskriterien, vielfach unklar. Dies führt dazu, dass viele Initiativen ohne klare Zielsetzung und Erfolgsmessung verbleiben (Bartelt & Röser, 2024b). Technologische und organisatorische Interoperabilität – insbesondere die Integration in bestehende Systeme wie CRM-, ERP- oder PIM-Lösungen – erfordert abteilungsübergreifende Zusammenarbeit und stellt mittelständische Unternehmen vor zusätzliche Herausforderungen (Bartelt, 2024).

Vor diesem Hintergrund ergibt sich die Notwendigkeit, ein Implementierungsframework zu entwickeln, das die spezifischen Herausforderungen sowie Hemmnisse adressiert und den Anforderungen des deutschen Mittelstands gerecht wird. In diesem Zusammenhang sollte es praxisorientiert und verständlich formuliert sein, damit Unternehmen die einzelnen Schritte und Empfehlungen direkt umsetzen können. Hierbei sind Flexibilität und Anpassungsfähigkeit essenziell, um unterschiedliche Unternehmensgrößen, Branchen und spezifische Rahmenbedingungen zu adressieren. Ebenso ist die Integration der Technologie in bestehende Prozesse und Systeme sicherzustellen, wobei technische, organisatorische und kulturelle Aspekte gleichermaßen zu berücksichtigen sind. Die Messbarkeit des Nutzens anhand quantitativer als auch qualitativer Bewertungskriterien ist ebenso erforderlich wie die Transparenz und Nachvollziehbarkeit der einzelnen Schritte. Darüber hinaus sind die aktive Partizipation der Mitarbeitenden sowie die Unterstützung von Change-Management-Maßnahmen als zentrale Erfolgsfaktoren zu berücksichtigen. Das Framework ist als iteratives System zu konzipieren, das kontinuierlich anhand von Feedback, Evaluation und neuen empirischen Erkenntnissen weiterentwickelt werden muss. Eine wissenschaftliche Fundierung bilden dabei die in den Kapiteln 5.2.1 sowie 5.2.2 herausgestellten prozessbeschreibenden sowie prozessbegleitenden Kategorien.

5.3.2 Konzeptmapping

5.3.2.1 Mapping prozessbeschreibende Kategorien

Die konzeptionelle Grundlage für das Implementierungsframework basiert auf einer systematischen Zuordnung der Kern- und Kontexttheorien (Kapitel 3.3) zu den prozessbeschreibenden und prozessbegleitenden Kategorien (Kapitel 5.2) sowie den praxisrelevanten Implikationen (Kapitel 5.2.4) innerhalb der nachfolgenden Kapitel.

Das Mapping der prozessbeschreibenden Kategorien verdeutlicht, dass die Diffusion-of-Innovations-Theory (Rogers, 2003), die Lean-Startup-Methodology (Ries, 2011) sowie die Dynamic-Capabilities-Theory (Teece et al., 1997) eine übergreifende, strukturgebende Funktion für das gesamte Prozessmodell besitzen. Sie untermauern insbesondere die Erkenntnis, dass der Implementierungsprozess generativer KI nicht als linearer Ablauf, sondern als zyklischer, lernorientierter Prozess zu verstehen ist. Die Diffusion-of-Innovations-Theory nach Rogers (2003) liefert hierfür eine zentrale theoretische Fundierung. Sie beschreibt die Phasen der Technologieadoption – von der ersten Problemidentifikation über die Pilotierung bis hin zur Skalierung – systematisch und hebt die Bedeutung sozialer Einbettung, individueller Adoptionsentscheidungen und organisationaler Lernprozesse hervor. Ergänzend dazu betont die Lean-Startup-Methodology von Ries (2011) die Rolle iterativer Entwicklung, Prototyping und kontinuierlicher Feedbackschleifen im Implementierungsprozess. Diese Theorie lässt sich insbesondere mit den in den praxisrelevanten Implikationen postulierten schnellen Lernzyklen sowie der adaptiven Anpassung im Implementierungsprozess in Beziehung setzen. Die Dynamic-Capabilities-Theory nach Teece et al. (1997) erweitert diese Perspektive. Sie stellt die Fähigkeit von Unternehmen in den Mittelpunkt, sich kontinuierlich an neue technologische und organisationale Anforderungen anzupassen, bestehende Ressourcen zu rekonfigurieren und nachhaltige Wettbewerbsvorteile durch organisationales Lernen und Innovationsfähigkeit sicherzustellen.

5.3.2.2 Mapping prozessbegleitende Kategorien

Im Zuge der Implementierungsstrategie und der strategischen Zielsetzungen als erste prozessbegleitende Kategorie (STRAT) wird die Notwendigkeit einer Balance zwischen langfristiger Orientierung und kurzfristiger Flexibilität besonders deutlich. Das Konzept der emergenten Strategie von Mintzberg (1985) trägt dem Umstand Rechnung, dass Strategien in Organisationen häufig nicht im Voraus vollständig geplant werden. Stattdessen werden

sie im Verlauf der Umsetzung durch Erfahrungen, Rückkopplungen und situative Anpassungen adaptiert. Diese Theorie ist unmittelbar anschlussfähig an die empirisch beobachtete Dynamik und Flexibilität der KI-Implementierung. Das Acht-Stufen-Modell des Wandels von Kotter (1996) bietet darüber hinaus einen praxisorientierten Rahmen für die Steuerung und Begleitung von Veränderungsprozessen. Es betont die Bedeutung von Kommunikation, Beteiligung und nachhaltiger Verankerung von Veränderungen und adressiert damit die bereits erläuterten Problematiken bei der Einführung generativer KI im Mittelstandskontext.

Die Integration der KI-Technologie (Kategorie: TECH) in bestehende Strukturen wird maßgeblich durch die Soziotechnische Systemtheorie nach Trist und Bamforth (1951) und das TOE-Framework von Tornatzky und Fleischer (1990) erklärt. Die Soziotechnische Systemtheorie (Trist & Bamforth, 1951) hebt die gleichwertige Berücksichtigung technischer, organisatorischer und kultureller Aspekte hervor und bietet eine interdisziplinäre Perspektive auf die Gestaltung komplexer sozio-technischer Systeme. Sie ist damit unmittelbar anschlussfähig an die empirisch beobachtete enge Verzahnung dieser Dimensionen im deutschen Mittelstand. Das TOE-Framework (Tornatzky & Fleischer, 1990) ergänzt diese Sichtweise, indem es die Wechselwirkungen zwischen technologischen, organisationalen und umweltbezogenen Aspekten systematisch analysiert und die Kontextsensitivität der Implementierung betont.

Für die Erfolgsmessung und Bewertung (Kategorie: EVAL) von KI-Anwendungen sind multidimensionale Ansätze erforderlich. Die Balanced Scorecard nach Kaplan & Norton (1996) ermöglicht eine ganzheitliche, strategisch ausgerichtete Erfolgsmessung, indem sie ökonomische, prozessuale, technologische und lernbezogene Aspekte integriert. Dieses Modell ist besonders geeignet, um die Wirkung von Implementierungsmaßnahmen systematisch zu evaluieren und die strategische Steuerung von KI-Anwendungen zu unterstützen. Das TAM von Davis (1989) fokussiert sich hingegen auf die Kernfaktoren „wahrgenommene Nützlichkeit“ und „wahrgenommene Benutzerfreundlichkeit“ und bietet eine robuste theoretische Basis, um die Akzeptanz und Nutzung generativer KI im Mittelstand zu analysieren und gezielt zu fördern.

Die Entwicklung und Umsetzung von KI-Roadmaps (Kategorie: FUT) ist als iterativer, dynamisch adaptierbarer Prozess zu verstehen, der durch Rückkopplungen zwischen strategischer Steuerung, Kompetenzaufbau und Technologieeinsatz geprägt ist. Für die Entwicklung von KI-Roadmaps liefert, wie bereits bei den prozessbeschreibenden Kategorien, die Dynamic-Capabilities-Theory nach Teece (1997) die konzeptionelle Grundlage, indem sie

die Fähigkeit zur kontinuierlichen Anpassung und zum organisationalen Lernen postuliert. Die Diffusion-of-Innovations-Theory nach Rogers (2003) ergänzt diese Perspektive und erklärt die Mechanismen für die Skalierung und die Übertragung von Innovationen auf neue Unternehmensbereiche, insbesondere durch den Einsatz von Pilotprojekten.

Nach der theoretischen Fundierung der prozessbeschreibenden und prozessbegleitenden Kategorien widmet sich das nachfolgende Kapitel den übergeordneten Querschnittserkenntnissen und Wechselwirkungen. Diese Analyse schafft die Basis für die anschließende Konsolidierung der Konzepte zu einem Gesamtmodell.

5.3.2.3 Darlegung Querschnittserkenntnisse und Wechselwirkungen

Als zentrale Querschnittserkenntnisse des Konzeptmappings wurden eine iterative Prozessarchitektur, die konsequente Integration technischer, organisatorischer und kultureller Aspekte sowie die Entwicklung hybrider Steuerungsmodelle identifiziert, die zentrale Vorgaben (Top-down) mit dezentraler Innovationskraft (Bottom-up) verbinden. Dabei sind eine kontextsensitive Erfolgsmessung und kontinuierlicher Kompetenzaufbau unverzichtbar für nachhaltige Implementierungserfolge.

Die Wechselwirkungen dieser Aspekte manifestieren sich in charakteristischen Dissenspunkten: Unternehmen stehen vor der Herausforderung, zwischen strategischer Planbarkeit und experimenteller Offenheit zu balancieren, zentrale Steuerung mit dezentraler Autonomie zu verbinden und technologische Machbarkeit mit kultureller Anschlussfähigkeit in Einklang zu bringen. Abhängigkeiten bestehen insbesondere darin, dass technologische Innovationen nur dann wirksam werden, wenn sie durch Change-Management, Kompetenzentwicklung und eine unterstützende Unternehmenskultur flankiert werden. Somit ist die Beziehung zwischen diesen Einflussfaktoren dynamisch und kontextabhängig zu verstehen. Sie bestimmen, inwieweit Unternehmen Innovationsfähigkeit, Akzeptanz und nachhaltige Wertschöpfung durch generative KI realisieren können. Die folgende Tabelle 14 fasst die identifizierten Querschnittserkenntnisse zusammen.

Tabelle 14: Zusammenfassung der Querschnittserkenntnisse und abgeleiteten Wechselwirkungen

Querschnittserkenntnis	Implizierter Dissenspunkt (Spannungsfeld)	Implikation für eine erfolgreiche Implementierung
1. Iterative Prozessarchitektur	Balance zwischen strategischer Planbarkeit und experimenteller Offenheit.	Das Framework muss sowohl eine klare Richtung vorgeben als auch Raum für agiles Lernen und Anpassungen (z.B. durch Build-Measure-Learn-Zyklen) lassen.
2. Hybride Steuerungsmodelle	Verbindung von zentraler Steuerung (Top-down) mit dezentraler Autonomie (Bottom-up).	Es müssen Governance-Strukturen geschaffen werden, die strategische Vorgaben mit der Innovationskraft und dem Fachwissen der Mitarbeitenden kombinieren.
3. Integration von Technik, Organisation & Kultur	Einklang von technologischer Machbarkeit mit organisatorischer und kultureller Anschlussfähigkeit.	Technologische Lösungen können nur wirksam werden, wenn sie durch flankierendes Change-Management, Kompetenzaufbau und eine innovationsfördernde Kultur getragen werden.
(Übergeordnet) Kontextsensitive Erfolgsmessung & Kompetenzaufbau	Durchgängige Wechselwirkung	Diese beiden Aspekte sind keine isolierten Punkte, sondern kontinuierliche Prozesse, die alle drei oben genannten Spannungsfelder beeinflussen und für eine nachhaltige Wertschöpfung unverzichtbar sind.

Quelle: Eigene Darstellung

Die dargestellten Querschnittserkenntnisse und Wechselwirkungen verdeutlichen die Bedeutung dynamischer Zusammenhänge für die erfolgreiche Implementierung generativer KI im Mittelstand. Aufbauend auf diesen Erkenntnissen wird im folgenden Kapitel die Konsolidierung prozessbegleitender und prozessbeschreibender Kategorien mit vorgenommen.

5.3.3 Konsolidierung prozessbeschreibender und prozessbegleitender Kategorien

5.3.3.1 Prozessphase 1: Problemidentifikation und Kontextanalyse

Der Erstentwurf des Implementierungsframeworks basiert auf der Konsolidierung der zuvor erarbeiteten prozessbeschreibenden und prozessbegleitenden Kategorien. Das Framework umfasst fünf Prozessphasen, die im Folgenden einzeln vorgestellt werden – beginnend mit der Phase der Problemidentifikation und Kontextanalyse (Abbildung 10). Das Framework ist zudem in Anhang J abgebildet.

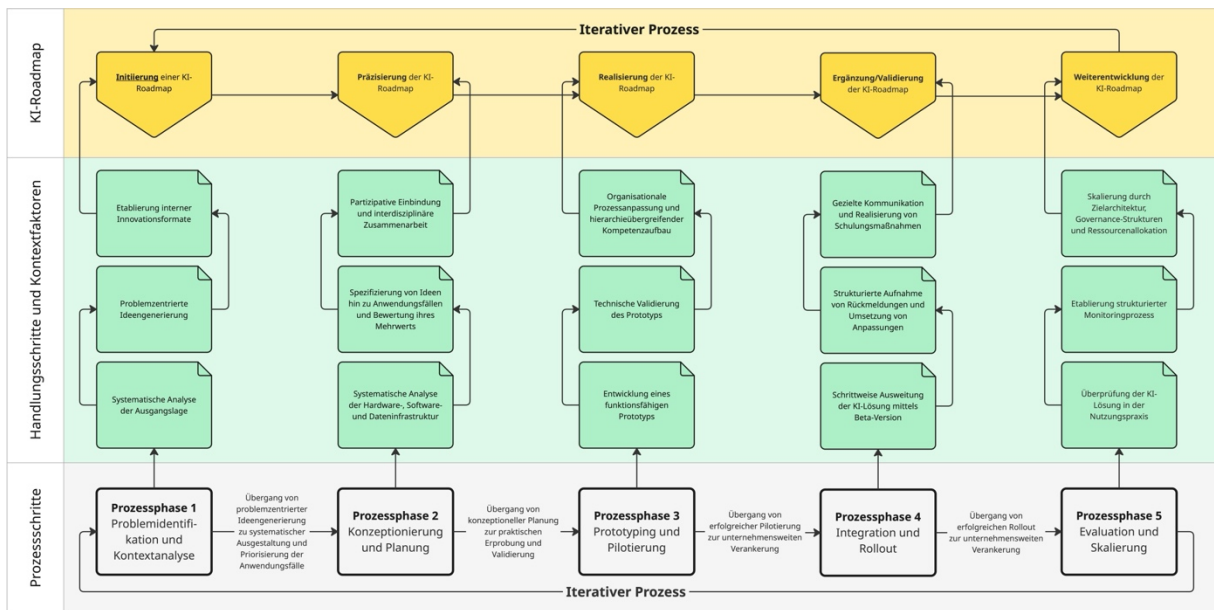


Abbildung 10: Erstentwurf des Implementierungsframeworks

Quelle: Eigene Darstellung

Die Konsolidierung der Kategorien verdeutlicht, dass mittelständische Unternehmen in der initialen Prozessphase der Implementierung mit einer ausgeprägten Unsicherheit hinsichtlich Nutzen, Relevanz und Anwendungsfeldern konfrontiert sind. Diese Beobachtung lässt sich im Zuge der Diffusion-of-Innovations-Theory (Rogers, 2003) interpretieren, wonach die Wahrnehmung und Kommunikation von Innovationen entscheidend für die spätere Adoptionsbereitschaft sind. Die Forschungsergebnisse legen nahe, dass die Implementierungsstrategie in dieser Phase nicht als statischer Zielkatalog, sondern als flexibler Orientierungsrahmen zu verstehen ist, der sowohl Top-down-Vorgaben als auch Bottom-up-Initiativen integriert. Hierdurch wird eine Balance zwischen strategischer Ambition und operativer Realität geschaffen, die für die spätere Legitimation und Akzeptanz der KI-Anwendungen unerlässlich ist.

Weiterhin zeigt die Konsolidierung, dass die problemzentrierte Ideengenerierung und die frühzeitige Prüfung technologischer Voraussetzungen zentrale Mechanismen darstellen, um Fehlinvestitionen und spätere Integrationsprobleme zu vermeiden. Diese Muster lassen sich mit der Dynamic-Capabilities-Theory (Teece et al., 1997) erklären, da die Fähigkeit zur kontinuierlichen Anpassung und zum organisationalen Lernen bereits in der Problemidentifikation berücksichtigt werden muss. Die Lean-Startup-Methodology (Ries, 2011) liefert hierfür die methodische Grundlage, indem sie die Bedeutung iterativer Entwicklung und schneller Lernzyklen betont. Die Kontextualisierung der Phase durch die Kategorien IMP, TECH,

EVAL und FUT ist somit nicht nur begleitend, sondern konstitutiv: Erst das Zusammenspiel dieser Kategorien ermöglicht es, Unsicherheiten produktiv zu adressieren, strategische Weichenstellungen vorzunehmen und die Grundlage für eine nachhaltige, anschlussfähige Implementierung zu legen.

Die erfolgreiche Durchführung der Problemidentifikation und Kontextanalyse in der initialen Prozessphase erfordert ein methodisch strukturiertes und kontextsensitives Vorgehen, bei dem die einzelnen Handlungsschritte eng mit den relevanten Kontextfaktoren verzahnt sind. Zu Beginn steht die systematische Kontextanalyse der Ausgangslage, in der bestehende Herausforderungen, Optimierungspotenziale und Zielbilder unter Einbeziehung von Methoden wie Design Thinking, Stakeholder-Interviews und technischen Visualisierungen durchgeführt und erhoben werden. Dieser Schritt wird maßgeblich durch die Zielsetzung beeinflusst, die frühzeitig klare Leitplanken und Orientierung schafft. Die explizite Integration von Top-down-Vorgaben und Bottom-up-Initiativen fördert dabei nicht nur die Kohärenz zwischen strategischer Ambition und operativer Realität, sondern trägt auch zur kulturellen Verankerung einer KI-affinen, lernbereiten Unternehmenskultur bei.

Im nächsten Schritt erfolgt die problemzentrierte Ideengenerierung, bei der der potenzielle Mehrwert für das Unternehmen im Vordergrund steht. Hier wirken technologische Kontextfaktoren als Filter: Bereits in der Problemidentifikation entscheidet sich, ob die identifizierten Anwendungsfälle mit den verfügbaren technologischen Ressourcen adressierbar sind. Die frühzeitige Prüfung technologischer Voraussetzungen und Restriktionen verhindert Fehlinvestitionen und legt die Grundlage für spätere Skalierbarkeit und Flexibilität. Die Kopplung von technologischer und organisationaler Entwicklung ist dabei entscheidend, um spätere Brüche zwischen technischer Lösung und organisationaler Realität zu vermeiden. Die Auswahl und Priorisierung der identifizierten Anwendungsfälle erfolgt anhand von Kriterien wie Wirksamkeit, Umsetzungsaufwand, strategischer Passung und Signalwirkung. Hierbei kommt den Bewertungsfaktoren eine zentrale Rolle zu: Die Entwicklung multidimensionaler Bewertungsraster ermöglicht eine objektive Auswahl und Priorisierung, schafft Transparenz und fördert die Legitimation gegenüber Stakeholdern. Die Etablierung von Erfolgsmessung als iterativer Prozess unterstützt zudem das organisationale Lernen und die kontinuierliche Anpassung der Zielbilder.

Zur Förderung der Qualität und Anschlussfähigkeit der generierten Ideen werden interne Innovationsformate wie Task Forces, Vorschlagsplattformen oder Pitch-Formate genutzt. Diese Formate sind nicht nur Ausdruck einer innovationsfreundlichen Unternehmenskultur,

sondern etablieren die Ideengenerierung als dauerhafte Ressource im Unternehmen. Der gesamte Prozess ist iterativ angelegt, sodass bei auftretenden Hinderungsgründen eine erneute Initiierung der Phase möglich ist. Langfristig etablierte Strukturen wie ein Center of AI oder Projektportfolios verankern die problemzentrierte Ideenfindung nachhaltig und sichern die strategische Anschlussfähigkeit.

Abschließend ist die Initiierung einer ersten KI-Roadmap ein integraler Bestandteil dieser Phase. Sie dient der Identifikation strategischer Entwicklungspfade, Kompetenzlücken und Innovationspotenziale und fungiert als Instrument zur Vermeidung von Pfadabhängigkeiten sowie zur Förderung der Zukunftsfähigkeit. Unter Pfadabhängigkeiten ist zu verstehen, dass frühe technologische oder organisatorische Festlegungen den späteren Handlungsspielraum des Unternehmens unnötig einschränken können. Die bewusste Offenhaltung von Alternativen und die Auswahl modularer, erweiterbarer KI-Technologien sichern die langfristige Innovations- und Anpassungsfähigkeit und verhindern, dass spätere Entwicklungen oder Kurskorrekturen durch frühe Entscheidungen blockiert werden. Mit der Initiierung einer KI-Roadmap kann zudem ermöglicht werden, technologische Trends und interne Innovationsimpulse systematisch zu antizipieren und in die weitere Entwicklung einzubinden. Werden diese Kontextfaktoren in der initialen Prozessphase nicht systematisch berücksichtigt, entstehen strukturelle Defizite.

5.3.3.2 Prozessphase 2: Konzeptionierung und Planung

Die zweite Prozessphase der Konzeptionierung und Planung markiert im Implementierungsframework den Übergang von der problemzentrierten Ideengenerierung zur systematischen Ausgestaltung und Priorisierung konkreter Anwendungsfälle. Im Theoriekontext ist diese Phase durch das Konzept der emergenten Strategie (Mintzberg & Waters, 1985) und das Acht-Stufen-Modell des Wandels (Kotter, 1996) fundiert, die die Bedeutung von Flexibilität, Kommunikation und partizipativer Zielentwicklung betonen. Die Soziotechnische Systemtheorie (Trist & Bamforth, 1951) und das TOE-Framework (Tornatzky & Fleischer, 1990) unterstreichen die Notwendigkeit, technologische, organisationale und umweltbezogene Aspekte integrativ zu betrachten. Für die Erfolgsmessung und Bewertung kommen Ansätze wie die Balanced Scorecard (Kaplan & Norton, 1996) und das TAM (Davis, 1989) zum Einsatz, da sie eine umfassende, strategisch ausgerichtete Steuerung sowie eine fundierte Analyse der Akzeptanz ermöglichen.

Die Konzeptionierung und Planung beginnt mit einer detaillierten Analyse der bestehenden Hardware-, Software- und Daten- und Organisationsstruktur, um Kompatibilitäten, Erweiterungsmöglichkeiten und notwendige Anpassungen zu identifizieren. Dieser Schritt wird maßgeblich durch die Zielsetzung beeinflusst, die eine klare Priorisierung und Kohärenz zwischen Unternehmensvision und operativen Zielen sicherstellt. Die in der ersten Prozessphase generierten Ideen werden fortführend zu konkreten Anwendungsfällen spezifiziert und hinsichtlich ihres Mehrwerts für das Unternehmen bewertet. Die Auswahl und Priorisierung erfolgt anhand klar definierter Kriterien wie technische Machbarkeit, wirtschaftlicher Nutzen, Dringlichkeit und regulatorische Anforderungen. Hierbei wirken die Bewertungsfaktoren als objektive Entscheidungsgrundlage und schaffen Transparenz sowie Legitimation gegenüber allen Stakeholdern.

Ein zentrales Element dieser Prozessphase ist die partizipative Einbindung aller relevanten Akteur*innen – von IT und Fachbereichen über Rechts- und Datenschutzabteilungen bis hin zum Management. Diese interdisziplinäre Zusammenarbeit stellt sicher, dass technische, rechtliche und organisatorische Belange gleichermaßen berücksichtigt werden und fördert die Akzeptanz sowie die Veränderungsbereitschaft im Unternehmen. Die Auswahl von Systemarchitekturen und Basistechnologien entscheidet darüber, ob die spezifizierten Anwendungsfälle technisch umsetzbar und skalierbar sind. Fehlerhafte oder zu kurzfristige Technologieentscheidungen könnten zu erheblichen Anpassungskosten führen und die spätere Skalierbarkeit einschränken. Die frühzeitige Berücksichtigung regulatorischer Anforderungen, insbesondere im Hinblick auf Datenschutz und Compliance, kann spätere Nachbesserungen oder Projektabbrüche verhindern und erhöht die Rechtssicherheit.

Die Konzeptions- und Planungsphase ist als evidenzbasierter Prozess zu verstehen, in dem Erfahrungen und neue Erkenntnisse systematisch in die Ausarbeitung eingespeist werden. Über gezielte Schulungsformate, die Entwicklung von KI-Richtlinien oder die Durchführung von Pilotprojekten werden sowohl das Wissen als auch die Akzeptanz im Unternehmen aufgebaut und gefestigt. Dabei schafft die Präzisierung der KI-Roadmap einen Rahmen für den Ausbau von KI-Anwendungen, verhindert eine Fragmentierung in kurzfristige Einzelprojekte und ermöglicht die gezielte Planung von Pilotprojekten, Skalierungsoptionen und Kompetenzaufbau. Sie identifiziert somit frühzeitig Kompetenzlücken und ermöglicht die Planung gezielter Weiterbildungsmaßnahmen sowie die Entwicklung neuer Rollenprofile, was für die nachhaltige Verankerung generativer KI im Unternehmen essenziell ist. Werden

diese Faktoren nicht explizit berücksichtigt, entstehen strukturelle Defizite, die den Erfolg der KI-Implementierung im weiteren Verlauf gefährden.

5.3.3.3 Prozessphase 3: Prototyping und Pilotierung

Die dritte Prozessphase des Prototypings und der Pilotierung nimmt im Implementierungsframework eine zentrale Rolle ein, da sie den Übergang von der konzeptionellen Planung zur praktischen Erprobung und Validierung markiert. Durch das Konzept der emergenten Strategie (Mintzberg & Waters, 1985) und das Acht-Stufen-Modell des Wandels (Kotter, 1996) wird die Phase theoretisch fundiert, da beide Ansätze die Bedeutung von iterativer Frameworkentwicklung und partizipativer Steuerung betonen. Die Dynamic-Capabilities-Theory (Teece et al., 1997) und die Diffusion-of-Innovations-Theory (Rogers, 2003) unterstreichen die Notwendigkeit kontinuierlicher Lernprozesse und die Fähigkeit, auf interne und externe Veränderungen flexibel zu reagieren. Für die Erfolgsmessung und Bewertung werden analog zur zweiten Prozessphase Ansätze wie die Balanced Scorecard (Kaplan & Norton, 1996) und das TAM (Davis, 1989) herangezogen, die eine gezielte Messung und Bewertung ermöglichen.

Die Umsetzung der Prototyping- und Pilotierungsphase beginnt mit dem Aufsetzen eines ersten Pilotprojektes, um frühzeitig die technische Umsetzbarkeit und den organisatorischen Nutzen der angedachten KI-Anwendung zu überprüfen. Die Verfügbarkeit geeigneter, strukturierter und zugänglicher Daten ist dabei ein relevantes Erfolgskriterium. Ist diese Voraussetzung nicht gegeben, sollte zunächst eine gezielte Datenaufbereitung und -strukturierung erfolgen.

Pilotprojekte werden bewusst in einem überschaubaren und risikoarmen Rahmen umgesetzt. Der Fokus wird auf Zielgruppen oder Fachbereichen gelegt, die für das Thema besonders relevant sind oder sich offen für neue Ansätze zeigen. Die technische Machbarkeit wird durch die Auswahl geeigneter Basistechnologien, die Integration in bestehende Systeme und die Nutzung modularer Architekturen sichergestellt. Eine frühe technische Validierung kann dabei Fehlinvestitionen verhindern und ermöglicht eine gezielte Fokussierung auf realisierbare Anwendungsfälle. Gleichzeitig ist die organisatorische Flankierung durch Prozessanpassungen, Kompetenzaufbau und begleitende Kommunikation unerlässlich, um die technische Innovation im Unternehmensalltag zu verankern und Akzeptanz zu schaffen.

Die Validierung des Anwendungsfalls erfolgt durch die Entwicklung und Anwendung spezifischer Bewertungskriterien, die sowohl technische Leistungsdaten als auch qualitative Indikatoren wie Feedback von Nutzer*innen und Akzeptanz erfassen. Methoden wie A/B-Tests und kontinuierliche Feedbackschleifen sind essenziell, um frühzeitig Problemstellungen zu identifizieren und Anpassungen vorzunehmen. Die iterative Optimierung des Prototyps und die enge Beteiligung von Nutzer*innen fördern das organisationale Lernen und die kontinuierliche Weiterentwicklung der Lösung. Erfolgreiche Pilotprojekte dienen somit nicht nur der technischen Validierung, sondern auch der kulturellen Verankerung von generativer KI im Unternehmen, indem sie Akzeptanz, Motivation und Vertrauen in die Technologie schaffen.

Die gezielte Planung von Kompetenzaufbau, die Entwicklung neuer Rollenprofile und die Integration partizipativer Formate sind dabei für die Realisierung der KI-Roadmap entscheidend, um die Innovationsfähigkeit und Zukunftsorientierung des Unternehmens zu stärken. Werden diese Kontextfaktoren nicht systematisch berücksichtigt, bleibt die Pilotierung ein isoliertes Experiment ohne nachhaltigen Effekt auf die Organisationsentwicklung und die spätere Skalierung generativer KI.

5.3.3.4 Prozessphase 4: Integration und Rollout

Die vierte Prozessphase der Integration und des Rollouts markiert im Implementierungsframework den Übergang von der erfolgreichen Pilotierung zur unternehmensweiten Verankerung der KI-Anwendung. Aus theoretischer Perspektive ist diese Phase durch die Sozio-technische Systemtheorie (Trist & Bamforth, 1951) und das TOE-Framework (Tornatzky & Fleischer, 1990) fundiert, die die gleichwertige Berücksichtigung technischer, organisatorischer und kultureller Aspekte betonen. Das Konzept der emergenten Strategie (Mintzberg & Waters, 1985) und das Acht-Stufen-Modell des Wandels (Kotter, 1996) unterstreichen ergänzend die Bedeutung von Kommunikation, Beteiligung und nachhaltiger Verankerung von Veränderungen. Für die Erfolgsmessung werden, wie in den vorherigen Prozessphasen, Ansätze wie die Balanced Scorecard (Kaplan & Norton, 1996) und das TAM (Davis, 1989) herangezogen.

Die Integration und der Rollout erfolgen als inkrementeller, mehrdimensionaler Prozess, der technische, organisatorische und kulturelle Aspekte gleichermaßen adressiert. Ausgangspunkt ist die schrittweise Ausweitung der KI-Anwendung von einer initialen Pilotgruppe auf breitere Nutzungsgruppen, etwa durch die Veröffentlichung einer unternehmensweiten

Beta-Version oder die Einbindung von komplementären Fachabteilungen. Diese Vorgehensweise ermöglicht es, frühzeitig Rückmeldungen aufzunehmen, Anpassungen vorzunehmen und Risiken zu minimieren. Die technische Umsetzung wird durch die Integration in bestehende IT-Systeme und Infrastrukturen realisiert. Dabei spielt die Entscheidung für eine modulare, offene und skalierbare Systemarchitektur eine zentrale Rolle, um langfristige Flexibilität und Erweiterbarkeit sicherzustellen. Nur so kann die KI-Anwendung nachhaltig in den operativen Betrieb überführt und auf weitere Unternehmensbereiche ausgerollt werden. Die Zusammenarbeit mit Systemherstellern und die Validierung der Anwendungsfälle sind dabei zentrale Erfolgsfaktoren.

Parallel zur technischen Umsetzung werden organisatorische Maßnahmen umgesetzt, insbesondere in Form von Schulungen, Trainings und begleitenden Kommunikationsmaßnahmen. Eine zentrale Absicht besteht darin, das notwendige Wissen bei den Mitarbeitenden aufzubauen, Akzeptanz zu fördern und die nachhaltige Verankerung der neuen Lösung im Unternehmen zu sichern. Die kommunikative Begleitung und die Einbindung der Mitarbeitenden sind entscheidend, um Akzeptanz und Vertrauen zu forcieren und Widerstände zu minimieren. Eine klare strategische Steuerung des Rollouts, die sowohl zentrale Steuerungselemente (z. B. Ressourcenallokation, Governance-Strukturen) als auch dezentrale Umsetzung (z. B. Einbindung von Fachabteilungen) integriert, ist unerlässlich, um Fragmentierung und Ineffizienz zu vermeiden. Die strategische Ausrichtung sorgt zudem dafür, dass die Integration der KI-Anwendung mit den übergeordneten Unternehmenszielen und -werten im Einklang steht.

Ein grundlegendes Verständnis für die eingesetzte Technologie und deren Wirkungsweise muss bei den Nutzer*innen aufgebaut werden, um eine tragfähige Implementierung zu gewährleisten. Die technische Integration muss durch begleitende organisatorische Maßnahmen flankiert werden, damit die Akzeptanz bei den Mitarbeitenden gesichert und die nachhaltige Verankerung der KI-Anwendung im Unternehmen gewährleistet werden kann. Dabei bildet die kontinuierliche Evaluation der technischen Funktionalität und der praktischen Anwendbarkeit, etwa durch Systemtests und strukturierte Feedbackmechanismen, die Grundlage für die fortlaufende Optimierung und Anpassung der Lösung. Schließlich müssen die Evaluationsergebnisse systematisch in die KI-Roadmap einfließen, um neue Anwendungsfelder zu ergänzen, Entwicklungspfade anzupassen und die Voraussetzungen für eine nachhaltige Skalierung zu schaffen. Die kontinuierliche Ergänzung und Validierung der KI-

Roadmap bleibt dabei ein zentrales Instrument, um technologische Trends und interne Innovationsimpulse frühzeitig zu antizipieren. Werden diese Kontextfaktoren in der Integrations- und Rolloutphase vernachlässigt, drohen Insellösungen, Akzeptanzprobleme sowie strukturelle Defizite, die den langfristigen Erfolg und die Weiterentwicklung generativer KI im Unternehmen gefährden.

5.3.3.5 Prozessphase 5: Evaluation und Skalierung

Die Evaluation und Skalierung markiert in der fünften Prozessphase den Übergang von der erfolgreichen Einführung einzelner Lösungen zur nachhaltigen, unternehmensweiten Verankerung. Sie übernimmt dabei die Aufgabe, die Wirksamkeit der implementierten Maßnahmen zu überprüfen sowie deren Skalierbarkeit sicherzustellen. Aus theoretischer Perspektive wird diese Phase durch das Konzept der emergenten Strategie (Mintzberg & Waters, 1985) und das Acht-Stufen-Modell des Wandels (Kotter, 1996) gerahmt, die die Notwendigkeit einer flexiblen, iterativen Steuerung und einer aktiven Einbindung der Mitarbeitenden betonen. Die Soziotechnische Systemtheorie (Trist & Bamforth, 1951) sowie das TOE-Framework (Tornatzky & Fleischer, 1990) unterstreichen, dass technologische, organisationale und kulturelle Aspekte integrativ betrachtet werden müssen, um eine nachhaltige Skalierung zu ermöglichen. Für die Erfolgsmessung und Bewertung sind wie zuvor die Balanced Scorecard (Kaplan & Norton, 1996) und das TAM (Davis, 1989) zentrale theoretische Grundlagen.

Die Evaluation und Skalierung ist als fortlaufender, lernorientierter Steuerungsprozess zu verstehen. Nach der initialen Implementierung steht die Überprüfung im Vordergrund, ob die KI-Anwendung stabil funktioniert, im Alltag genutzt wird und die Erwartungen der Nutzer*innen sowie der Projektverantwortlichen erfüllt. Hierbei werden sowohl technische Kennzahlen wie Systemperformance und Verfügbarkeit als auch qualitative Rückmeldungen aus der Nutzungspraxis herangezogen. Die Kombination dieser quantitativen und qualitativen Daten bildet die Grundlage für eine evidenzbasierte Weiterentwicklung.

Im weiteren Verlauf wird ein strukturierter Monitoring-Prozess etabliert, der kontinuierlich die Stabilität, Nutzungsintensität und organisationale Anschlussfähigkeit der Lösung überprüft. Performance-Dashboards und Feedbackschleifen dienen dazu, Erfahrungswissen zu dokumentieren und gezielt in die Weiterentwicklung einzubringen. Die Evaluation umfasst dabei nicht nur die technische Funktionalität, sondern auch die Akzeptanz und den tatsäch-

lichen Mehrwert im Arbeitsalltag. Für die Skalierung ist es entscheidend, erfolgreiche Lösungen schrittweise auf weitere Unternehmensbereiche oder Personengruppen zu übertragen. Dieser inkrementelle Ansatz ermöglicht es, die Technologie nachhaltig zu verankern und organisationale Lernprozesse zu fördern. Erfolgsentscheidend ist eine differenzierte, multidimensionale Erfolgsmessung, die technische, ökonomische, prozessuale sowie nutzerbezogene und strategische Effekte systematisch erfasst. Nur so kann sichergestellt werden, dass die Skalierung auf einer belastbaren Datenbasis erfolgt und alle relevanten Wirkungsebenen berücksichtigt werden. Die regelmäßige Auswertung von Kennzahlen und dem Feedback von Nutzer*innen ermöglicht es, Schwachstellen frühzeitig zu erkennen, Optimierungsmaßnahmen einzuleiten und die Implementierung iterativ weiterzuentwickeln. Die Evaluation liefert zudem die empirische Basis für die Legitimation weiterer Investitionen und die strategische Steuerung der Skalierung. Sie schafft Transparenz gegenüber Stakeholdern und ermöglicht eine evidenzbasierte Kommunikation über den Erfolg und die Weiterentwicklung der KI-Anwendungen.

Die strategische Steuerung der Skalierung erfordert eine klare Rahmung durch Zielarchitekturen, Governance-Strukturen und Ressourcenallokationen, die an die Evaluationsergebnisse angepasst werden. Nur so kann eine nachhaltige und unternehmensweite Ausweitung gelingen. Die strategische Einbettung sorgt dafür, dass die Skalierung nicht als isolierter Rollout, sondern als integrativer, adaptiver Prozess verstanden wird. Die Übertragung erfolgreicher Prototypen auf andere Bereiche erfolgt unter Berücksichtigung von Stabilität, Nutzungsintensität und organisationaler Passung. Die technische Integration muss so gestaltet sein, dass erfolgreiche Lösungen problemlos auf weitere Unternehmensbereiche übertragen werden können. Dies erfordert offene Schnittstellen, modulare Architekturen und eine enge Verzahnung mit bestehenden Systemen. Dabei ist die kontinuierliche Überwachung und Anpassung der technischen Systeme entscheidend, um Stabilität, Sicherheit und Leistungsfähigkeit im laufenden Betrieb zu gewährleisten. Gleichzeitig ist die Förderung einer lernorientierten, KI-affinen Unternehmenskultur und die institutionalisierte Integration von Change-Management- und Weiterbildungsmaßnahmen notwendig, um die nachhaltige Verankerung zukünftiger KI-Anwendungen zu sichern. Die KI-Roadmap dient weiterhin als strategischer Orientierungsrahmen, um bestehende Anwendungsfelder weiterzuentwickeln, Kompetenzlücken zu schließen und Innovationspotenziale systematisch zu erschließen. Insgesamt ist die Evaluation und Skalierung als integrativer, adaptiver und evidenzbasierter

Prozess zu verstehen, der die Grundlage für nachhaltigen Unternehmenserfolg und kontinuierliche Innovation legt.

Nachdem der Erstentwurf des Implementierungsframeworks mit der Beschreibung dieser fünften Phase nun vollständig dargelegt ist, folgt im nächsten Schritt dessen Validierung. Demnach präsentiert das nachfolgende Kapitel die Ergebnisse der durchgeführten Validierungsgespräche und beginnt mit der Bewertung der Plausibilität und Realisierbarkeit des Modells.

5.4 Ergebnisse der Validierungsgespräche

5.4.1 Validierung der Plausibilität und Realisierbarkeit

Die im Rahmen der Framework Analysis durchgeführten Validierungsgespräche hatten zum Ziel, den in Kapitel 5.3.3 entwickelten Erstentwurf des Implementierungsframeworks einer Überprüfung durch sieben Expert*innen zu unterziehen. Ein zentraler Fokus lag dabei auf der Bewertung der allgemeinen Plausibilität und der praktischen Realisierbarkeit. Das vorgestellte Prozessmodell gliedert sich in die fünf Phasen (1) Problemidentifikation & Kontextanalyse, (2) Lösungsdesign & Konzeption, (3) Prototyping & Pilotierung, (4) Implementierung & Integration sowie (5) Evaluation & Skalierung. Es ist mehrheitlich als plausibel, schlüssig und praxisnah bewertet worden. Bestätigt wurde, dass die dargestellte Abfolge eine logische und nachvollziehbare Struktur für die Implementierung von generativer KI darstellt. Die Einschätzung wird durch den Vergleich der Prozesslogik mit dem etablierten CRISP-DM-Modell unterstrichen, was die Anschlussfähigkeit des Frameworks an bekannte Standards der Datenanalyse und Softwareentwicklung indiziert. Die Tabelle 15 fasst die in den Validierungsgesprächen geäußerten Einschätzungen zur Plausibilität und Realisierbarkeit des Erstentwurfes prägnant zusammen.

Tabelle 15: Zusammenfassung der Validierungsgespräche

Interviewte Person (IP) ¹⁹	Plausibilität und Realisierbarkeit Framework (PL)
IP4	Bewertet das Framework als „sehr anschlussfähig“, aber nur für Personen mit einem methodischen Ansatz (<i>Transkript Validierungsgespräch IP4</i> , persönliche Kommunikation, 22. September 2025).
IP39	Bezeichnet das Framework als „vernünftiges Vorgehen“ für einen Softwareentwicklungsprozess (<i>Transkript Validierungsgespräch IP39</i> , persönliche Kommunikation, 11. September 2025).
IP5	Hält das Framework für verständlich und praxisnah, insbesondere durch die Nähe zum internationalen Standard CRISP-DM (<i>Transkript Validierungsgespräch IP5</i> , persönliche Kommunikation, 18. September 2025).
IP25	Findet sich und die Praxis in den 5 Prozessschritten wieder und vermisst keine wesentlichen Aspekte (<i>Transkript Validierungsgespräch IP25</i> , persönliche Kommunikation, 13. September 2025).
IP38	Bewertet das Framework als „gut“ und „klassisch, was man destilliert mitbekommt – was funktioniert“ (<i>Transkript Validierungsgespräch IP38</i> , persönliche Kommunikation, 11. September 2025).
IP11	Bezeichnet das Framework als „sehr schlüssig“ und eine gute Abstraktion der tatsächlichen Arbeitsweise (<i>Transkript Validierungsgespräch IP11</i> , persönliche Kommunikation, 11. September 2025).
IP8	Beschreibt das Framework als „perfekt erklärt“ und eine praxisorientierte Herangehensweise, die „genauso anwendbar“ ist (<i>Transkript Validierungsgespräch IP8</i> , persönliche Kommunikation, 11. September 2025).

Quelle: Eigene Darstellung

Ein zentrales und wiederkehrendes Ergebnis²⁰ ist die hohe Bedeutung der Iterativität sowie die prozessuale Flexibilität. Die Expert*innen betonten, dass die Phasen in der Praxis nicht als starrer, streng sequenzieller Ablauf verstanden werden dürfen. Vielmehr sei der Prozess von iterativen Schleifen und der Möglichkeit von Sprüngen zwischen den Phasen geprägt. Insbesondere wurde darauf hingewiesen, dass bereits in frühen Phasen, wie dem Prototyping (Phase 3), Aspekte späterer Phasen, wie die Skalierbarkeit (Phase 5), strategisch mitgedacht werden müssen. Eine adäquate visuelle Darstellung dieser prozessualen Flexibilität wurde als ein wesentlicher Aspekt für die Weiterentwicklung und die praktische Anwendbarkeit des Implementierungsframeworks erachtet.

¹⁹ Es handelt sich hierbei um die Expert*innen mit den höchsten Expertisescores.

²⁰ Die dargestellten Ergebnisse stellen eine thematische Synthese der Validierungsgespräche dar. Aus Gründen der Lesbarkeit wird auf Einzelreferenzen verzichtet; die Belegstellen sind der Datenmatrix in Anhang K zu entnehmen.

Über diese Bewertung hinaus lieferten die Expert*innen ausführliches Feedback zu jeder einzelnen Phase des Prozesses. Hinsichtlich der ersten Phase, wurde geäußert, dass der Prozess nicht nur durch die Identifikation von „Problemen“, sondern ebenso durch das proaktive Erkennen von „Chancen“ und „Potenzialen“ initiiert werden kann. Die strategische Verankerung der KI-Initiative in den übergeordneten Unternehmenszielen wurde dabei als kritischer Erfolgsfaktor hervorgehoben. In Bezug auf die zweite Phase wurde die Priorisierung der Vielzahl an generierten Ideen als auch die Depriorisierung entsprechender Ideen als erfolgsentscheidender Aspekt genannt. Als weitere essenzielle Elemente wurden die frühzeitige, holistische Einbindung aller relevanten Fachabteilungen sowie die bewusste Make-or-Buy-Entscheidung erwähnt. Im Zuge der dritten Phase wurde eine wesentliche Veränderung der Expert*innen postuliert: Anstelle von reinen POCs liege der Fokus derzeit auf der Entwicklung von ausbaufähigen MVPs, die von Beginn an die spätere Skalierbarkeit berücksichtigen. Zudem wurde auf die Notwendigkeit der Validierung der Prototypen durch Domain-Expert*innen hingewiesen. Im Kontext der vierten Phase, wurde die Bedeutung der technischen Anbindung an vor- und nachgelagerte Systeme als zentraler Aspekt genannt. Darüber hinaus wurde auf das Fehlen der Themen Testing und Qualitätssicherung sowie der systematischen Durchführung von Schulungsmaßnahmen in dieser Phase hingewiesen. Letztere seien entscheidend, um der im Prozessverlauf oft abnehmenden Beteiligung der Mitarbeitenden entgegenzuwirken. Ferner wurde die Notwendigkeit der Berücksichtigung abteilungsübergreifender Synergieeffekte angemerkt. Bezüglich der letzten Phase, der Evaluation und Skalierung (Phase 5), wurde die Notwendigkeit einer multidimensionalen Erfolgsmessung betont, die sowohl qualitative als auch quantitative Metriken und KPIs (AI Economics) umfasst. Weiterhin wurde der aktive Einbezug des Feedbacks der Endanwender*innen als essenziell erachtet. Kritisch hinterfragt wurde zudem der Begriff „Skalierung“ und eine differenziertere Betrachtung der Weiterentwicklungsmöglichkeiten angeregt.

Nachdem nun die Rückmeldungen zu den einzelnen Prozessphasen aus den Validierungsgesprächen dargelegt wurden, richtet sich der Blick im nächsten Schritt auf die identifizierten Dissenspunkte und kontroversen Ergebnisse. Diese wurden in den Validierungsgesprächen gezielt angesprochen und bilden den Ausgangspunkt der folgenden Analyse.

5.4.2 Darlegung der Dissenspunkte und kontroversen Ergebnisse

Ein wesentliches Ziel der Validierungsgespräche war die kritische Überprüfung der in Kapitel 5.2.3 herausgearbeiteten Dissenspunkte und kontroversen Ergebnisse. Hierzu bietet Tabelle 16 eine strukturierte Übersicht der in den Validierungsgesprächen analysierten Dissenspunkte und deren Ergebnisse. Sie fasst die ursprünglichen Konfliktlinien, die Entwicklung im Diskurs mit den Expert*innen sowie den jeweils erreichten Konsens oder bestehenbleibenden Dissens zusammen.

Tabelle 16: Analytierte Dissenspunkte und deren Ergebnisse

Hauptkategorie (Dissenspunkt)	Ursprünglicher Dissens (gemäß Kapitel 5.2.3)	Ergebnis der Validierungsgespräche (Konsensbildung)	Fazit der Analyse
IM - Steuerungslogik	Top-down (zentrale Kontrolle) vs. Bottom-up (dezentrale Initiative)	Beide Ansätze sind für sich allein unzureichend. Erfolg entsteht nur durch eine Symbiose: Top-down liefert den strategischen Rahmen, die Legitimation und die Ressourcen; Bottom-up liefert das Prozesswissen, die Praxisnähe und fördert die Akzeptanz.	<u>Konsens</u> durch Synthese. Der Dissens wird aufgelöst, indem ein bidirektionales, sich gegenseitig bedingendes Framework als idealer Weg etabliert wird.
TE – Technologieauswahl	Technologische Machbarkeit vs. Kulturelle/Organisatorische Anschlussfähigkeit	Die Entscheidung ist keine ideologische, sondern eine rationale Abwägung. Es wird ein Kriterienkatalog etabliert, der u.a. Anwendungsfall, Datensensibilität und interne Kompetenzen umfasst.	<u>Konsens</u> durch Kontextualisierung. Der Dissens wird durch einen gemeinsamen, pragmatischen Entscheidungsprozessersetzt, der auf kontextabhängigen Kriterien basiert.
EB – Erfolgsmessung	Quantitative ROI-Messung vs. Qualitative, akzeptanzorientierte Bewertung	Die Bewertung muss mehrdimensional sein. Der Fokus verschiebt sich je nach Projektphase (früh: qualitativ; reif: quantitativ), strategischer Bedeutung und Zeithorizont des Nutzens („Time-to-Value“).	<u>Konsens</u> durch Differenzierung. Der Dissens wird durch ein flexibles, phasen- und zielabhängiges Bewertungsmodell aufgelöst, dass beide Metrik-Arten integriert.
KI – Zukunftsausrichtung	Geplante „Masterplan“-Strategie vs. Emergente, flexible Strategieentwicklung	Die Begriffe werden neu geordnet: Die strategische „KI-Roadmap“ ist geplant und übergeordnet. Der operative „Use-Case-Prozess“ ist agil. Mitarbeiterbefähigung („Training“) wird als zentrales strategisches Zukunftsthema identifiziert.	<u>Konsens</u> durch konzeptionelle Klärung. Der Dissens, der auf einer begrifflichen Unschärfe beruhte, wird durch die Trennung von strategischer und operativer Ebene aufgelöst.

Quelle: Eigene Darstellung

Die Analyse zeigt, dass die ursprünglich identifizierten „Entweder-oder“-Positionen in den Validierungsgesprächen durchweg aufgelöst und in einen Konsens überführt wurden. Der identifizierte Dissens zwischen einer zentral gesteuerten Top-down-Logik und dezentralen Bottom-up-Initiativen wurde von den Expert*innen einstimmig aufgelöst. Es herrscht ein Konsens darüber, dass eine erfolgreiche Implementierungsstrategie zwingend eine Symbiose beider Ansätze erfordert. Es wurde argumentiert, dass beide Steuerungslogiken notwendige, aber für sich allein unzureichende Funktionen erfüllen. Während die Top-down-Steuerung die strategische Richtung, die Legitimation und die notwendigen Ressourcen sicherstellt, liefern Bottom-up-Initiativen das entscheidende Prozesswissen, die Praxisnähe und fördern die Akzeptanz in der Belegschaft. Der ursprüngliche Dissens bestand somit nicht in der grundsätzlichen Richtigkeit eines Ansatzes, sondern in der fehlerhaften Annahme, dass eine Entscheidung zwischen beiden getroffen werden müsse.

Auch der vermeintliche Dissens zwischen einer rein technologisch getriebenen Auswahl und der Notwendigkeit der kulturellen und organisatorischen Anschlussfähigkeit wurde in einen Konsens überführt. Anstelle einer ideologischen Positionierung etablierten die Expert*innen einstimmig einen pragmatischen, auf unterschiedlichen Kriterien basierenden Entscheidungsprozess. Die Auswahl der Technologie und des Integrationsgrades ist demnach das Ergebnis einer rationalen, kontextspezifischen Abwägung. Als entscheidende Kriterien wurden übereinstimmend der Anwendungsfall (Use Case), die Art und Sensibilität der Daten sowie die vorhandenen internen Kompetenzen und Ressourcen genannt.

Der Dissens zwischen einer rein quantitativen, ROI-getriebenen Erfolgsmessung und einer qualitativen, auf Akzeptanz ausgerichteten Bewertung wurde ebenfalls aufgelöst. Die Expert*innen postulieren eine flexible, mehrdimensionale Erfolgsmessung, deren Schwerpunktsetzung sich nach dem Reifegrad des Projekts, seiner strategischen Bedeutung und dem erwarteten Zeithorizont des Nutzens (Time-to-Value) richtet. Es besteht Einigkeit darüber, dass in frühen Phasen qualitative KPIs im Vordergrund stehen sollten, während in den fortgeschrittenen Phasen quantitative Metriken unerlässlich sind, wobei strategische Erwägungen eine rein zahlengetriebene Bewertung übersteuern können.

Der Dissens zwischen einem „Masterplan“ und einer emergenten, flexiblen Strategieentwicklung, wurde durch eine klare konzeptionelle Trennung der strategischen und operativen Ebene aufgelöst. Es herrscht Einigkeit darüber, dass es auf der strategischen Ebene eine geplante, übergeordnete „KI-Roadmap“ geben muss, die den Gesamtkontext berücksichtigt und Leitplanken setzt. Der Prozess zur Umsetzung der daraus abgeleiteten Projekte – der

eigentliche „Use-Case-Implementierungsprozess“ – muss jedoch agil und pragmatisch sein, um Lernen und flexible Anpassungen zu ermöglichen. Der Dissens beruhte somit im Kern auf einer begrifflichen Unschärfe, die von den Expert*innen korrigiert wurde.

Die Ergebnisse der Framework Analysis verdeutlichen, dass die zuvor identifizierten Kontroversen durch die Validierungsgespräche in einen Konsens überführt werden konnten. Anstelle der Kontroversen tritt ein von den Expert*innen getragener Konsens, der die identifizierten Gegensätze als komplementäre Aspekte eines flexiblen, kontextabhängigen Gesamtmodells integriert. Dieser validierte Konsens bildet die entscheidende Grundlage für die gezielte Weiterentwicklung des Implementierungsframeworks. Nachdem die konzeptionellen Unschärfen nun beseitigt wurden, werden im nachfolgenden Kapitel strukturelle und inhaltliche Optimierungsvorschläge abgeleitet.

5.5 Weiterentwicklung des Implementierungsframeworks

5.5.1 Ableitung struktureller und inhaltlicher Optimierungsvorschläge

Auf Grundlage der zuvor dargestellten Ergebnisse wurden drei strukturelle sowie sieben inhaltliche Optimierungsvorschläge für die Weiterentwicklung des Implementierungsframeworks abgeleitet. Diese zielen darauf ab, die im Erstentwurf vorgestellten Prozessphasen zu schärfen, prozessuale Lücken zu schließen und die erforderliche Praxisnähe zu erzielen und gliedern sich in strukturelle Anpassungen sowie inhaltliche Präzisierungen. Es wird an dieser Stelle hervorgehoben, dass die Bewertung der Optimierungsvorschläge im nachfolgenden Kapitel 5.5.2 erfolgt. Die deskriptive Vorstellung der Vorschläge steht im Vordergrund dieses Kapitels.

Die Tabelle 17 fasst die ersten strukturellen Optimierungsvorschläge zusammen und konsolidiert die Anstöße aus den Validierungsgesprächen. Sie gleicht zudem jeden Vorschlag mit dem Erstentwurf des Implementierungsframeworks ab und stellt den möglichen Beitrag der Optimierung heraus.

Tabelle 17: Zusammenfassung der strukturellen Optimierungsvorschläge

Vorschlag Nr.	Kurztitel des Optimierungsvorschlags	Berücksichtigung im Erstentwurf (Kapitel 5.2.3)	Möglicher Beitrag der Optimierung
1	Iterativität & Validierungsschleifen	Konzeptionell als „zyklischer, lernorientierter Prozess“ angelegt	Visuelle Transformation des Konzepts in ein agiles, zyklisches Prozessmodell zur Verdeutlichung der Praxisnähe
2	Begriffliche Einordnung und Schärfung der KI-Roadmap	Nicht ausreichend trennscharf; „KI-Roadmap“ wird prozessintern verwendet und nicht als Strategieinstrument	Schaffung einer klaren, logischen Einordnung und Schärfung der Begrifflichkeit
3	Umgebender strategischer Rahmen	Als „prozessbegleitende Kontextfaktoren“ textlich erwähnt	Visuelle und konzeptionelle Aufwertung zu einem permanenten, grundlegenden Rahmen (Enabler) statt nur Begleitfaktoren

Quelle: Eigene Darstellung

Die Vorschläge Nr. 1 bis Nr. 3 zielen auf die strukturelle Optimierung und das konzeptionelle Verständnis des Frameworks ab. Ein zentraler Vorschlag betrifft die stärkere Betonung der Iterativität und die Integration von Validierungsschleifen. Die Expert*innen bewerteten ein starres, lineares Phasenmodell einstimmig als nicht praxisgerecht für die agile und oft unvorhersehbare Realität von KI-Anwendungen. Es wurde argumentiert, dass ein rein sequenzielles Vorgehen die notwendigen Lernprozesse, die Revision von Annahmen und die Reaktion auf technische Herausforderungen torpediert (*Transkript Validierungsgespräch IP25*, persönliche Kommunikation, 13. September 2025). Der Vorschlag sieht daher vor, Rückkopplungspfeile zwischen allen Phasen zu integrieren, die die Möglichkeit von Sprüngen verdeutlichen sollen, während explizite Validierungsschleifen die Notwendigkeit der kontinuierlichen Überprüfung durch Stakeholder- und Nutzer*innenfeedback unterstreichen.

Darüber hinaus wird eine konzeptionelle Trennung von „Strategischer KI-Roadmap“ und „Use-Case-Implementierungsprozess“ angeregt. Die Analyse verdeutlicht, dass der Begriff „KI-Roadmap“ für den dargestellten operativen Prozess eines einzelnen Anwendungsfalls unzutreffend erscheint, da eine strategische Roadmap den gesamten Unternehmenskontext und die Marktentwicklung umfassen sollte (*Transkript Validierungsgespräch IP5*, persönliche Kommunikation, 18. September 2025). Um diese begriffliche Unschärfe zu beheben, wird vorgeschlagen, das Prozessmodell selbst umzubenennen und die „Strategische KI-Roadmap“ als ein übergeordnetes, dem Prozess vorgelagertes Artefakt darzustellen. Die

stattdessen geforderte „Use-Case-Auflistung“ sollte dabei als dynamisches Bindeglied zwischen der strategischen und der operativen Ebene fungieren (*Transkript Validierungsgespräch IP4*, persönliche Kommunikation, 22. September 2025).

Aus den Validierungsgesprächen geht weiter hervor, dass der Implementierungserfolg von strategischen Voraussetzungen abhängt, die mehr als nur begleitende Aspekte einzelner Phasen sind. Ohne die symbiotische Zusammenarbeit von Management und Mitarbeitenden, eine klare Daten- und Cloud-Strategie sowie eine kontinuierliche Befähigung der Belegschaft fehlt dem Implementierungsframework das erforderliche Fundament (*Transkript Validierungsgespräch IP8*, persönliche Kommunikation, 11. September 2025; *Transkript Validierungsgespräch IP38*, persönliche Kommunikation, 11. September 2025). Der Optimierungsvorschlag sieht daher vor, das Implementierungsframework visuell mit einem Rahmen zu umschließen. Das Fundament würde somit aus drei visuellen Teilen bestehen und könnte die strategischen Voraussetzungen: „Symbiotische Steuerungslogik“ (Top-down & Bottom-up), „Technologie- & Datenstrategie“ (Cloud oder On-Premise) sowie „Mitarbeitendenbefähigung (Training)“ enthalten.

Analog den strukturellen Vorschlägen werden nachfolgend die inhaltlichen Optimierungen vorgestellt. Die Tabelle 18 fasst diese zusammen und stellt ebenso den Bezug zum Erstentwurf sowie den möglichen Beitrag der Optimierung heraus.

Tabelle 18: Zusammenfassung der inhaltlichen Optimierungsvorschläge

Vor-schlag Nr.	Kurztitel des Optimierungsvorschlags	Berücksichtigung im Erstentwurf (Kapitel 5.2.3)	Möglicher Beitrag der Optimierung
4	Konkrete Resultate pro Phase	Nicht explizit berücksichtigt; nur Aktivitäten und Ziele werden beschrieben	Übersetzung von Prozesszielen in konkrete, messbare Ergebnisse zur Steigerung der Verbindlichkeit und Nachvollziehbarkeit
5	AI Economics & Budgetfrage	Implizit als Kriterium (wirtschaftlicher Nutzen) vorhanden	Explizite Verankerung als obligatorischer Handlungsschritt (Phase 2) und Evaluationspunkt (Phase 5) zur Betonung der kritischen Relevanz.
6	Erweiterung auf „Chancen“	Einseitig als „Problemidentifikation“ gerahmt	Erweiterung der Perspektive, um auch proaktive, innovationsgetriebene Initiativen abzubilden.
7	Betonung der Priorisierung	Als Handlungsschritt bereits angelegt	Stärkere Gewichtung und Hervorhebung als zentraler, obligatorischer Meilenstein aufgrund der hohen Praxisrelevanz.
8	Ersetzung POC durch MVP	Nicht explizit differenziert; Begriff „Prototyp“ wird verwendet	Terminologische und konzeptionelle Modernisierung zur Betonung von Nachhaltigkeit und Skalierbarkeit von Beginn an.
9	Integration von Testing	Nicht explizit berücksichtigt	Schließung einer prozesslogischen Lücke zur Risikominimierung und Sicherstellung der Akzeptanz der Nutzer*innen vor dem breiten Rollout.
10	Präzisierung von „Skalierung“	Als zentraler Begriff in Phase 5 vorhanden	Differenzierung des Begriffs und Erweiterung der Phase auf „Weiterentwicklung“, um vielfältigere Folgeprozesse abzubilden.

Quelle: Eigene Darstellung

Bezugnehmend auf den Vorschlag Nr. 4 wird die Definition und Benennung konkreter Resultate für jede Prozessphase angeregt. Die Forderung nach klar definierten Ergebnissen, zielt darauf ab, die Nachvollziehbarkeit zu erhöhen und den Prozessfortschritt messbar zu machen (*Transkript Validierungsgespräch IP39*, persönliche Kommunikation, 11. September 2025). Es wird daher vorgeschlagen, jede Phase um das Feld „Zentrales Ergebnis/Artefakt“ zu ergänzen. Beispiele hierfür sind ein „Problem-/Chancen-Canvas“ (Phase 1), ein „Priorisierter Use-Case-Auflistung“ (Phase 2), ein „funktionsfähiges Minimum Viable Product (MVP) & Validierungsbericht“ (Phase 3), eine „Integriertes KI-Anwendung & Test-/Schulungsdokumentation“ (Phase 4) sowie ein „Evaluationsbericht & Aktualisierter Use-Case-Auflistung“ (Phase 5).

Zudem wird die explizite Verankerung der „AI Economics“ und der Budgetklärung vorgeschlagen (Vorschläge Nr. 5 und Nr. 6). Die Expert*innen identifizierten die Finanzierung

und die wirtschaftliche Rechtfertigung als kritische Hürden (*Transkript Validierungsgespräch IP4*, persönliche Kommunikation, 22. September 2025; *Transkript Validierungsgespräch IP11*, persönliche Kommunikation, 11. September 2025). Um diesem Umstand Rechnung zu tragen, sollte in der zweiten Phase der Handlungsschritt „Wirtschaftlichkeitsanalyse (Time-to-Value) & Budgetklärung“ eingefügt und in der fünften Phase die „Messung des ROI“ als zentraler Evaluationspunkt verankert werden. Des Weiteren wird eine Erweiterung der Perspektive innerhalb der ersten Phase angeregt, da die alleinige Fokussierung auf „Probleme“ eine rein reaktive Haltung impliziert. Die Expert*innen betonten, dass KI-Anwendungen ebenso aus proaktiv erkannten „Chancen“ oder „Opportunitäten“ entstehen können (*Transkript Validierungsgespräch IP5*, persönliche Kommunikation, 18. September 2025; *Transkript Validierungsgespräch IP39*, persönliche Kommunikation, 11. September 2025). Daher wird vorgeschlagen, die erste Phase in „Problem- & Chancenidentifikation“ umzubenennen.

Im Zuge der Vorschläge Nr. 7 und Nr. 8 wird eine stärkere Betonung der Priorisierung und der abteilungsübergreifenden Zusammenarbeit innerhalb der zweiten Phase gefordert. Die Expert*innen bezeichnen die Priorisierung und insbesondere die Depriorisierung als kritischste Hürde (*Transkript Validierungsgespräch IP4*, persönliche Kommunikation, 22. September 2025; *Transkript Validierungsgespräch IP25*, persönliche Kommunikation, 13. September 2025), weshalb die Handlungsschritte „Use-Case-Priorisierung“ und „Abteilungsübergreifendes Stakeholder-Meeting“ aufgenommen werden sollten. Eine weitere inhaltliche Detaillierung betrifft die Modernisierung des Prototyping-Ansatzes in der dritten Phase von „POC“ zu „MVP“. Die Expert*innen argumentierten, dass es angesichts der fortgeschrittenen Technologie nicht mehr darum gehe, ob etwas funktioniert, sondern wie es nachhaltig implementiert wird (*Transkript Validierungsgespräch IP39*, persönliche Kommunikation, 11. September 2025). Der Optimierungsvorschlag sieht daher vor, den Begriff „POC“ im gesamten Framework durch „MVP“ zu ersetzen, um die Orientierung an einer von Beginn an skalierbaren Architektur zu verdeutlichen.

Bezugnehmend auf Vorschlag Nr. 9 wird die Integration von „Testing & Qualitätssicherung“ als expliziter Schritt in der vierten Phase vorgeschlagen, um eine festgestellte prozesslogische Lücke zu schließen. Ein Rollout ohne strukturierte Tests birgt laut Expert*innenaussagen ein hohes Risiko, die Akzeptanz der Nutzer*innen nachhaltig zu beschädigen (*Transkript Validierungsgespräch IP39*, persönliche Kommunikation, 11. September 2025). Daher sollte eine formale Testphase mit ausgewählten Beta-Usern und etablierten Feedback-

Schleifen als entscheidender Schritt zur Risikominimierung vor dem eigentlichen Rollout eingefügt werden. Abschließend wird eine Präzisierung des Skalierungsbegriffs und eine Neuausrichtung der fünften Phase innerhalb von Vorschlag Nr. 10 angeregt. Es wurde argumentiert, dass der Begriff „Skalierung“ im Sinne eines exponentiellen Wachstums für interne Unternehmensanwendungen oft unpassend ist (*Transkript Validierungsgespräch IP5*, persönliche Kommunikation, 18. September 2025). Um die Vielfalt der möglichen Folgeaktivitäten besser abzubilden, sollte die fünfte Phase in „Evaluation & Weiterentwicklung“ umbenannt werden.

Nachdem die Optimierungsvorschläge vorgestellt wurden, folgt nun deren kritische Bewertung, um ihren Beitrag zur Weiterentwicklung des Frameworks zu beurteilen und über ihre finale Integration zu entscheiden.

5.5.2 Bewertung der Optimierungsvorschläge und Beitrag zur Weiterentwicklung des Implementierungsframeworks

Zu Beginn dieses Kapitels ist zu konstatieren, dass die Optimierungsvorschläge den Erstentwurf nicht verwerfen, sondern dessen konzeptionelle Basis aufgreifen und präzisieren. Im Folgenden wird jeder einzelne Vorschlag aus dem vorangegangenen Kapitel hinsichtlich dessen Realisierbarkeit sowie dessen spezifischen Beitrag zur Weiterentwicklung des Erstentwurfs beurteilt.

Hinsichtlich der Prozessdarstellung erweist sich die visuelle Hervorhebung der Iterativität (Vorschlag Nr. 1) als notwendige Konkretisierung und wird in die finale Framework-Entwicklung einfließen. Der Gedanke eines zyklischen Prozesses war im Erstentwurf bereits textlich als „zyklischer, lernorientierter Prozess“ angelegt, die rein visuelle Darstellung eines linearen Frameworks wurde von den Expert*innen jedoch als zu starr und nicht praxisgerecht kritisiert. Der spezifische Beitrag dieser Optimierung liegt darin, dass durch die Ergänzung von Rückkopplungspfeilen und expliziten Validierungsschleifen je Prozessphase die prozessuale Flexibilität zu einem integralen, visuellen Bestandteil wird. Dies schließt nicht nur die von den Expert*innen aufgezeigte Lücke zwischen der konzeptionellen Beschreibung und einer unmissverständlichen visuellen Repräsentation. Es erhöht auch die Praxisnähe und legitimiert explizit ein agiles, lernorientiertes Vorgehen, das von den Expert*innen als essenziell erachtet wird.

Eine weitere strukturelle Optimierung betrifft die konzeptionelle Trennung von „Strategischer KI-Roadmap“ und „Use-Case-Implementierungsprozess“ (Vorschlag Nr. 2). Die Analyse der Expert*innenkritik verdeutlichte, dass der Begriff „KI-Roadmap“ für den dargestellten operativen Prozess eines einzelnen Anwendungsfalls unzutreffend ist, da eine strategische Roadmap den gesamten Unternehmenskontext umfassen muss. Obwohl dieser Vorschlag konzeptionell valide ist, wurde im Zuge der finalen Framework-Entwicklung entschieden, diesen Vorschlag nicht in die Finalversion zu integrieren. Diese Entscheidung beruht auf der Notwendigkeit, den Fokus des Frameworks – den operativen Implementierungsprozess – zu wahren. Eine Integration der vorgelagerten, strategischen Planungsprozesse würde das Framework überladen und dessen Praktikabilität als übersichtliche Handlungsanleitung für Projektteams schmälern. Der Vorschlag wird dabei jedoch nicht verworfen. Vielmehr wird die strategische Perspektive auf die KI-Roadmap im konzeptionellen Überbau des Frameworks als essenzielles, dem Prozess vorgelagertes Artefakt verortet.

Die strukturellen Anpassungen werden durch die Integration eines umgebenden strategischen Rahmens (Vorschlag Nr. 3) komplettiert. Während der Erstentwurf die entsprechenden Faktoren als „prozessbegleitende Kontextfaktoren“ korrekt identifizierte, hebt der Optimierungsvorschlag diese auf die relevante strategische Ebene und wird somit in der finalen Framework-Entwicklung berücksichtigt. Die Darstellung als umgebender Rahmen verdeutlicht, dass es sich nicht nur um Begleitaspekte, sondern um strategische Voraussetzungen für den gesamten Prozess handelt. Für die Weiterentwicklung des Frameworks ergibt sich hieraus der wesentliche Vorteil, dass eine klare visuelle und konzeptionelle Trennung zwischen dem operativen Prozess und den strategischen Voraussetzungen geschaffen wird. Der Kernprozess wird dadurch von strategischen Überlegungen entlastet, während die Einbettung in die Gesamtstrategie des Unternehmens (Steuerung, Technologie, Personal) verankert wird. Das Framework gewinnt so an strategischer Tiefe, ohne an operativer Klarheit zu verlieren.

Eine entscheidende inhaltliche Schärfung des Frameworks resultiert aus der Umsetzung von Vorschlag Nr. 4, der die Definition konkreter Resultate für jede Prozessphase fordert. Im Erstentwurf fehlten diese spezifischen, überprüfbaren Ergebnisse/Artefakte, was von den Expert*innen als wesentliche Schwächung der Verbindlichkeit und Praxisnähe kritisiert wurde (*Transkript Validierungsgespräch IP8*, persönliche Kommunikation, 11. September 2025; *Transkript Validierungsgespräch IP39*, persönliche Kommunikation, 11. September

2025). Durch die beschlossene Umsetzung wandelt sich das Framework zu einem ergebnisorientierten Steuerungsinstrument. Jede Phase schließt nun mit einem klar definierten Artefakt ab, wie beispielsweise einem „Problem- & Chancen-Canvas“ oder einem „Validierungsbericht“. Dies schafft nicht nur klare Meilensteine und erhöht die Verbindlichkeit für das Projektteam, sondern steigert auch die Nachvollziehbarkeit für Stakeholder, da der Fortschritt an greifbaren Ergebnissen gemessen wird. Das Framework definiert somit nicht nur das „Wie“ (Aktivitäten), sondern auch das „Was“ (Resultate) und schließt eine wesentliche Lücke des Erstentwurfs.

In ähnlicher Weise erfolgt die explizite Verankerung der „AI Economics“ (Vorschlag Nr. 5) als erforderliche Konkretisierung. Der Gedanke des wirtschaftlichen Nutzens war im Erstentwurf zwar implizit als Priorisierungskriterium vorhanden, der Vorschlag hebt diesen jedoch auf die Ebene eines expliziten und damit unumgänglichen Handlungsschrittes, sodass der Vorschlag in der finalen Framework-Entwicklung berücksichtigt wird. Die Einführung des Begriffs „AI Economics“ schärft diesen Aspekt und führt zu einer frühzeitigen, fundierten Rechtfertigung von Investitionen. Durch die Etablierung dieses Handlungsschrittes gewinnt das Framework an betriebswirtschaftlicher Fundierung. Es wird sichergestellt, dass die Auswahl von Anwendungsfällen nicht nur auf technischer Machbarkeit beruht, sondern von Beginn an auf die ökonomischen Ziele des Unternehmens ausgerichtet ist.

Eine weitere notwendige Anpassung ist die Umbenennung der ersten Prozessphase in „Problem- & Chancenidentifikation“ (Vorschlag Nr. 6). Die ursprüngliche, problemfokussierte Ausrichtung wurde als zu reaktiv kritisiert, weshalb sich für eine Umsetzung des Vorschlags entschieden wurde. Durch die explizite Aufnahme von „Chancen“ wird das Implementierungsframework auch für proaktive, innovationsgetriebene Initiativen anwendbar, was seine strategische Relevanz und Flexibilität deutlich steigert. Der Beitrag zur Weiterentwicklung des Frameworks besteht darin, dass sein Anwendungsbereich maßgeblich erweitert wird. Es wird nicht länger nur als reaktives Instrument zur Lösung bestehender Probleme, sondern ebenso als proaktives Werkzeug positioniert. Diese Erweiterung stellt sicher, dass das Framework die unternehmerische Realität – Effizienzsteigerung durch Problemlösung und Wachstum durch Chancennutzung – gleichermaßen adressiert. Schließlich wird die strategische Anschlussfähigkeit des Modells erhöht, da es explizit dazu anleitet, beide Perspektiven in der initialen Phase zu berücksichtigen.

Aufbauend darauf ist die stärkere Betonung der Priorisierung und der abteilungsübergreifenden Zusammenarbeit in der zweiten Phase (Vorschlag Nr. 7) eine wertvolle Akzentuierung. Obwohl diese Aspekte im Erstentwurf bereits angelegt waren, sieht die Optimierung eine stärkere Hervorhebung der Priorisierung sowie Depriorisierung im Zuge der Handlungsschritte vor und wird somit in die finale Framework-Entwicklung einfließen. Außerdem wirkt die Nennung eines „abteilungsübergreifenden Stakeholder-Meetings“ als Mechanismus der Gefahr der „Analyse-Paralyse“ und der Entwicklung von Silo-Lösungen entgegen. Für die Weiterentwicklung des Frameworks ist dieser Vorschlag von Bedeutung, da er ein als kritisch konnotiertes Praxisproblem direkt adressiert. Dadurch wandelt sich das Framework von einem rein deskriptiven zu einem präskriptiven, anleitenden Instrument, das nicht nur beschreibt, *dass* priorisiert werden sollte, sondern mit dem Stakeholder-Meeting einen konkreten Mechanismus etabliert, *wie* dies geschehen soll.

Eine wichtige terminologische Anpassung ist die Umbenennung des Prototyping-Ansatzes von „POC“ zu „MVP“ (Vorschlag Nr. 8). Der Erstentwurf sprach hier noch unspezifisch von einem „funktionsfähigen Prototypen“, weshalb eine Umsetzung des Vorschlags beschlossen wurde. Die Umstellung auf den MVP-Begriff trägt der von den Expert*innen beschriebenen Entwicklung in der Praxis Rechnung. Sie schärft die Intention der Phase weg von einem reinen Machbarkeitsbeweis hin zur Schaffung einer nachhaltigen, von Beginn an auf Skalierbarkeit und Integration ausgelegten Grundlage. Durch die Umstellung auf den MVP-Begriff wird die Intention des Implementierungsframeworks verdeutlicht. Es verweist darauf, bereits in der dritten Phase nicht nur die technische Machbarkeit zu prüfen, sondern die Grundlage für eine langfristig wertstiftende und technisch robuste Lösung zu schaffen. Diese Anpassung stellt sicher, dass bereits in einer frühen Phase die Weichen für eine erfolgreiche Integration und spätere Weiterentwicklung gestellt werden.

Eine weitere, intensiv diskutierte Optimierung betrifft die Integration von „Testing & Qualitätssicherung“ als expliziter Schritt in der vierten Phase (Vorschlag Nr. 9). Die von den Expert*innen geäußerte Warnung vor einem Rollout ohne strukturierte Tests und dem damit verbundenen Risiko für die Akzeptanz der Nutzer*innen ist von praktischer Relevanz. Trotz dieser validen Argumentation wurde im Zuge der finalen Framework-Entwicklung entschieden, diesen Vorschlag nicht visuell umzusetzen. Die Begründung hierfür liegt im Verständnis von Testing und Qualitätssicherung als eine phasenübergreifende, kontinuierliche Aktivität und nicht als einmaliger, isolierter Prozessschritt. Eine detaillierte Betrachtung zeigt, dass Test- und Validierungsaufgaben bereits immanenter Bestandteil mehrerer Phasen sind:

In der dritten Phase erfolgt die funktionale Validierung des MVPs, in der vierten Phase die Integrationstests und in der fünften Phase die kontinuierliche Überwachung in der Nutzungspraxis. Die Aufnahme eines separaten Schrittes würde daher eine Redundanz erzeugen und fälschlicherweise eine starre Wasserfall-Logik suggerieren, was dem agilen Grundgedanken des Frameworks widerspräche. Stattdessen wird die Forderung der Expert*innen umgesetzt, indem die Handlungsschritte innerhalb der bestehenden Phasen geschärft und explizit um Test- und Validierungsaufgaben ergänzt werden. Dies bewahrt die strategische Abstraktionsebene des Kernmodells, ohne die Bedeutung der Qualitätssicherung zu vernachlässigen.

Abschließend stellt die Präzisierung des Skalierungsbegriffs innerhalb von Phase 5 (Vorschlag Nr. 10) eine sinnvolle Differenzierung dar, sodass der Vorschlag in der finalen Framework-Entwicklung berücksichtigt wird. Die Kritik am unpräzisen Begriff „Skalierung“ wird aufgegriffen und die Phase durch die Umbenennung in „Evaluation & Weiterentwicklung“ für ein breiteres, praxisnäheres Spektrum an Folgeaktivitäten geöffnet. Dies verdeutlicht, dass die Skalierung auf weitere Gruppen von Nutzer*innen eine von mehreren Optionen neben etwa der funktionalen Erweiterung eines bestehenden Use Cases ist. Diese Neuausrichtung ist für die Weiterentwicklung des Frameworks von Bedeutung, da sie dessen zyklischen und lernorientierten Charakter vollendet. Anstatt einen linearen Prozess mit einem festen Endpunkt zu suggerieren, positioniert der Begriff „Weiterentwicklung“ die fünfte Phase als einen strategischen Übergang, dessen Ergebnisse direkt in neue Iterationen einfließen können. Das Framework wird somit nicht als reines Projektmanagement-Tool positioniert.

Die Gesamtheit der in diesem Kapitel bewerteten und umzusetzenden Optimierungen führt zur Finalversion des Implementierungsframeworks. Zur Visualisierung der wesentlichen Anpassungen, zeigt die nachfolgende Abbildung 11 eine Gegenüberstellung des Erstentwurfes und der Finalversion. Die letztere Version kann zudem Anhang L entnommen werden.

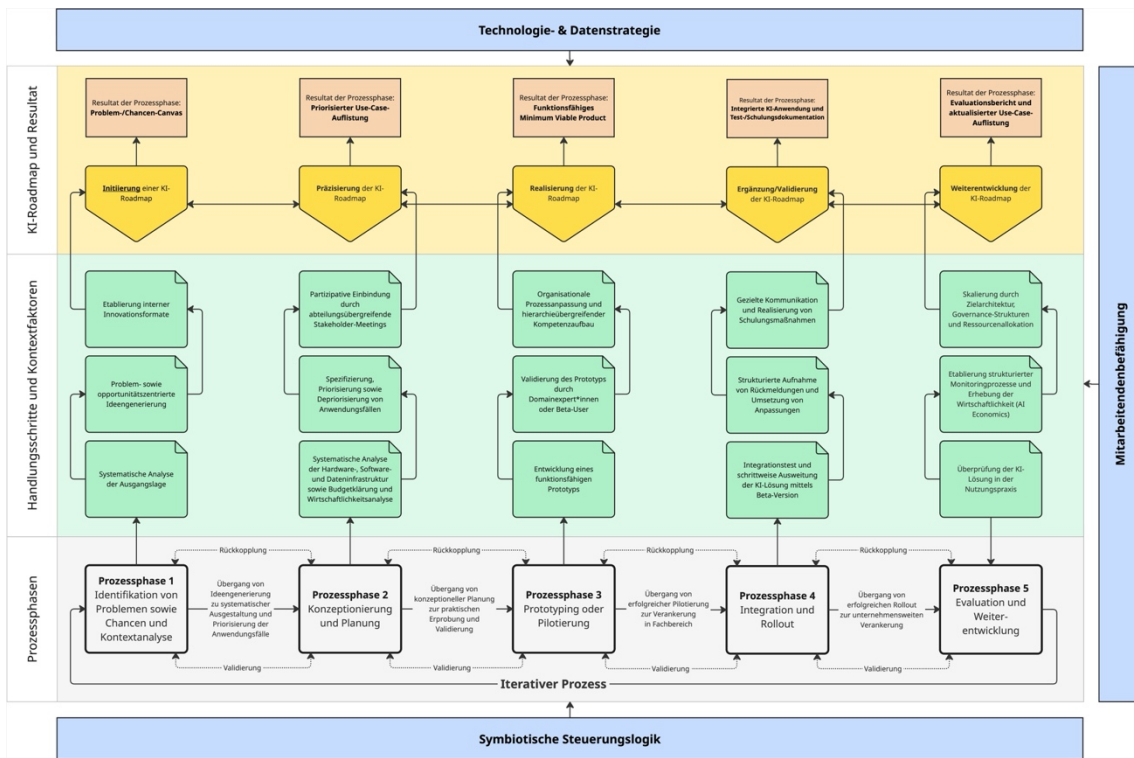
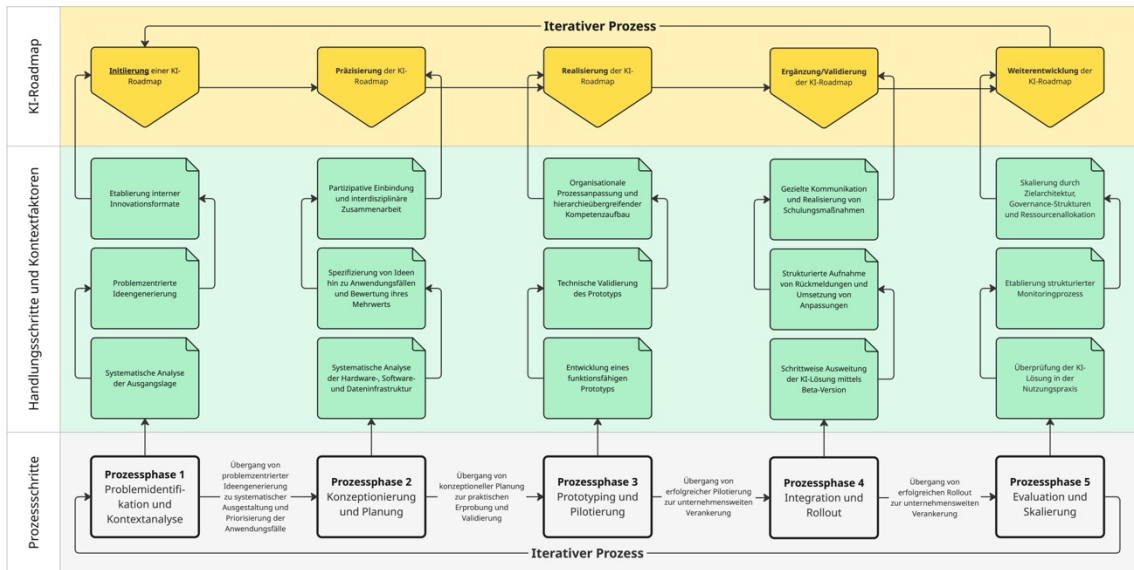


Abbildung 11: Gegenüberstellung Erstentwurf (oben) und Finalversion des Implementierungsframeworks (unten)

Quelle: Eigene Darstellung

Um die praktische Anwendbarkeit und den Mehrwert der vorgenommenen Anpassungen zu veranschaulichen, wird das finale Implementierungsframework im nachfolgenden Kapitel exemplarisch am Marketingprozess demonstriert.

5.6 Theoretische Adaption des Implementierungsframeworks am Marketingprozess

5.6.1 Auswahl und theoretische Einordnung des Anwendungsfalls

Der letzte Schritt der in Kapitel 4.3.3.2 vorgestellten Methodik nach Hevner et al. (2004) und Jabareen (2009) erfordert die theoretische Adaption des entwickelten Artefakts. Dementsprechend wird das in Kapitel 5.5.2 finalisierte Implementierungsframework anhand eines praxisrelevanten Anwendungsfalls demonstriert. Zu diesem Zweck wird zunächst auf Basis des in Kapitel 2.2.3 dargelegten Forschungsstandes ein Anwendungsfall im Fachbereich Marketing begründet ausgewählt. Anschließend wird dieser innerhalb des Marketingprozesses eingeordnet, um eine theoretische Fundierung zu gewährleisten.

Der in dieser Arbeit dargelegte Forschungsstand zeigt, dass die automatisierte Erstellung von Inhalten für verschiedene Marketingkanäle zu den wesentlichen Anwendungsfeldern von generativer KI zählt (Davenport et al., 2020; Han et al., 2021; Mikalef & Gupta, 2021). Insbesondere die Produktion von Texten für Social-Media-Plattformen, für die Suchmaschinenoptimierung (SEO) sowie für Suchmaschinenwerbung (SEA) wurde als relevant identifiziert (Fehrenbach et al., 2024; He & Zhang, 2023). Innerhalb dieser Bereiche führt der Einsatz von generativer KI dazu, die Effizienz zu steigern und eine konsistente, crossmediale Kommunikation sicherzustellen. Aufgrund der Praxisrelevanz und Aktualität dieser Online-Marketing-Instrumente wird die Content-Erstellung in den Bereichen Social-Media, SEO und SEA für die nachfolgende theoretische Adaption ausgewählt. Als theoretische Grundlage und zur Einordnung des Anwendungsfalls dient der in der Wissenschaft etablierte Marketingprozess nach Runia et al. (2019). Das Grundlagenwerk strukturiert den Marketingprozess in fünf aufeinander aufbauende Phasen: (1) die Marketinganalyse, (2) die Bestimmung von Marketingzielen, (3) die Ableitung von Marketingstrategien, (4) der Einsatz von Marketinginstrumenten und (5) die Marketingkontrolle. Die Erstellung von Content für Social-Media, SEO und SEA ist eine operative Maßnahme innerhalb der Kommunikationspolitik des Marketing-Mixes. Demzufolge wird der Anwendungsfall der vierten Phase, dem Einsatz von Marketinginstrumenten, zugeordnet.

Für die nachfolgende theoretische Adaption wird bewusst auf die Darstellung weiterer Anwendungsfälle für die übrigen Prozessphasen verzichtet. Diese Fokussierung dient primär dazu, die prozessuale Validität und Übertragbarkeit des entwickelten Implementierungsframeworks vorzustellen, anstatt eine oberflächliche Anleitung für jede denkbare Anwendung zu liefern. Demnach gewährleistet die Adaption eines spezifischen Anwendungsfalls

die notwendige methodische Schärfe und zeigt, dass das Implementierungsframework anwendbar ist.

5.6.2 Erläuterung des Anwendungsszenarios

Für die theoretische Adaption wird ein fiktives Szenario aus der mittelständischen Unternehmenspraxis beschrieben. Es ist an dieser Stelle hervorzuheben, dass die dargelegte Vorgehensweise von einer klassischen Fallstudienforschung abzugrenzen ist. Während eine Fallstudie das Ziel verfolgt, ein Phänomen tiefgehend in seinem Kontext zu analysieren (Yin, 2014), dient die hier durchgeführte Adaption nicht dem Zweck der vollständigen Durchdringung des Unternehmensfalls selbst, sondern der exemplarischen Anwendung eines fiktiven Szenarios.

Zur theoretischen Adaption des Implementierungsframeworks wird der Anwendungsfall wie folgt charakterisiert: Das Unternehmen ist ein produzierendes Unternehmen im B2B-Bereich mit circa 150 Mitarbeitenden. Das Marketing-Team besteht aus einer Person als Head of Marketing, die sowohl strategische als auch operative Aufgaben verantwortet, einer Fachkraft im Bereich Marketing-Management für operative Tätigkeiten sowie drei Mitarbeitenden im Bereich Grafik. Das Team steht vor der Herausforderung, dass die manuelle Erstellung von zielgruppenspezifischem Content für die verschiedenen Online-Kanäle (insbesondere SEO-Texte für den Blog und Social-Media-Posts für LinkedIn) zeitintensiv und fehleranfällig ist. Gleichzeitig ist sich das Management der Potenziale von generativer KI bewusst, sieht sich jedoch mit einem zentralen Problem konfrontiert: Die Nutzung öffentlich zugänglicher KI-Anwendungen wie ChatGPT ist aufgrund der DSGVO-Richtlinien und der Gefahr des Abflusses unternehmenssensibler Daten untersagt. Es besteht somit der Bedarf für eine sichere und DSGVO-konforme KI-Anwendung zur Content-Erstellung. Die bestehende technische Infrastruktur umfasst das genutzte E-Commerce-System und ein LinkedIn-Unternehmensprofil. Spezifische KI- oder erweiterte SEO-Tools sind bislang nicht im Einsatz.

In den folgenden Unterkapiteln wird die systematische Anwendung des finalisierten Implementierungsframeworks demonstriert. Die Darstellung erfolgt phasenweise und beinhaltet die Anwendung der einzelnen Handlungsschritte sowie die jeweiligen Resultate einer Prozessphase, um die prozessuale Validität und praktische Anwendbarkeit des Frameworks zu beschreiben.

5.6.3 Anwendung auf Prozessphase 1: Problem- und Chancenidentifikation

Die erste Phase dient der systematischen Analyse der Ausgangslage sowie der Identifikation von abteilungsspezifischen Problemstellungen oder möglichen Chancen, die mit dem Einsatz generativer KI einhergehen können. Zudem stellt sie sicher, dass die Implementierungsinitiative nicht allein technologiegetrieben, sondern aus einem konkreten organisationalen Bedarf entsteht.

Im Rahmen der theoretischen Adaption wird dieser erste Schritt durch eine systematische Kontextanalyse zur Erhebung der Ausgangslage im zuvor beschriebenen Unternehmen initiiert. Das Marketing-Team arbeitet das zentrale Problemfeld präzise heraus. Demnach ist die manuelle Erstellung von zielgruppenspezifischem Content für den Unternehmensblog und den LinkedIn-Kanal zeitintensiv und bindet personelle Ressourcen. Dieser Umstand führt dazu, dass die Frequenz und Reichweite der Online-Marketing-Aktivitäten hinter den Marketingzielen zurückbleiben. Darauf aufbauend erfolgt eine vertiefende problem- und chancenorientierte Ideengenerierung zum Einsatz generativer KI in Form eines Workshops, mit dem weitere potenzielle Mehrwerte für die Marketingabteilung herausgearbeitet werden. Hierbei zeigt sich die im Framework verankerte symbiotische Steuerungslogik: Während die Notwendigkeit zur Effizienzsteigerung als Bottom-up-Impuls aus dem operativen Alltag des Marketing-Teams entsteht, formuliert das Management eine klare Top-down-Vorgabe. Diese strategische Leitplanke – das Verbot der Nutzung öffentlich zugänglicher KI-Anwendungen aufgrund von DSGVO-Bedenken – triggert den Ideenprozess entscheidend. Um diesen Prozess zu strukturieren und innerhalb der Marketingabteilung dauerhaft zu etablieren, wird ein regelmäßig stattfindender KI-Workshop als Innovationsformat genutzt.

Im vorliegenden Anwendungsszenario formiert sich schließlich eine Arbeitsgruppe, bestehend aus dem Head of Marketing und der Marketing-Management-Fachkraft sowie einer Person aus der Geschäftsführung. In dieser Konstellation wird das weitere Vorgehen abgestimmt, wodurch eine breite Akzeptanz im Marketing-Team und eine Verbindlichkeit seitens der Geschäftsführung sichergestellt werden soll. Als zentrales Ergebnis dieser ersten Phase resultiert ein Problem- und Chancen-Canvas. Dieses Dokument fasst die gewonnenen Erkenntnisse systematisch zusammen und enthält die Beschreibung des Kernproblems (ineffiziente, manuelle Content-Erstellung), die strategische Chance (Skalierung der Content-Produktion) sowie eine erste Lösungsidee (DSGVO-konforme KI-Anwendung). Mit diesem ausgearbeiteten Canvas wird die erste Phase des Implementierungsprozesses erfolgreich abgeschlossen und zur zweiten Prozessphase übergeleitet.

5.6.4 Anwendung auf Prozessphase 2: Konzeptionierung und Planung

Aufbauend auf dem Problem- und Chancen-Canvas startet diese Phase mit einer detaillierten Analyse der bestehenden Software-, Daten- und Hardwarestruktur innerhalb der Marketingabteilung. Die gegründete Arbeitsgruppe stellt fest, dass neben dem E-Commerce-System und dem LinkedIn-Profil keine spezifischen KI- oder SEO-Tools vorhanden sind. Die Analyse der Datenstruktur identifiziert vorhandene Blogbeiträge, technische Produktdatenblätter und Marketingbroschüren als potenzielle, qualitativ hochwertige Datenquellen, die für die KI-Anwendung als Quelle genutzt werden könnten. Letztlich wird die Hardwarestruktur betrachtet und festgestellt, dass keine ausreichenden Ressourcen zum eigenständigen Betrieb eines LLMs zur Verfügung stehen. Im darauffolgenden Schritt wird die Grundlage für eine Wirtschaftlichkeitsanalyse geschaffen und eine verbindliche Budgetklärung angefordert, um die ökonomische Tragfähigkeit des Vorhabens sicherzustellen. Im Sinne der „AI Economics“ wird die potenzielle „Time-to-Value“ berechnet. Hierfür werden die geschätzten Lizenzkosten einer DSGVO-konformen KI-Anwendung den eingesparten Arbeitsstunden für die manuelle Content-Erstellung gegenübergestellt. Diese Analyse ergibt ein positives Kosten-Nutzen-Verhältnis und dient als fundierte Grundlage für die formale Beantragung eines Projektbudgets bei der Geschäftsführung.

Ein zentraler Meilenstein dieser Phase ist das abteilungsübergreifende Stakeholder-Meeting, das die partizipative Einbindung aller relevanten Akteure aus komplementären Abteilungen vorsieht und eine verbindliche Use-Case-Priorisierung zum Ziel hat. Die Arbeitsgruppe lädt hierzu Vertreter*innen aus dem Vertrieb, dem Produktmanagement, der IT sowie den externen Datenschutzbeauftragten ein. Im Meeting wird das Problem- und Chancen-Canvas sowie der Anwendungsfall vorgestellt. Der Vertrieb bestätigt den dringenden Bedarf an qualitativ hochwertigem Content zur Lead-Generierung, während das Produktmanagement die Chance sieht, technische Inhalte schneller und zielgruppengerechter aufzubereiten. Die IT und der Datenschutzbeauftragte geben grünes Licht unter der Bedingung, dass eine zertifizierte, DSGVO-konforme Cloud-Lösung zum Einsatz kommt. Durch diesen Austausch wird eine Silo-Lösung vermieden und eine breite organisationale Unterstützung für das Vorhaben geschaffen.

Basierend auf den Ergebnissen des Stakeholder-Meetings und der Budgetfreigabe erfolgt die Auswahl geeigneter Systemarchitekturen und Basistechnologien. Die IT-Abteilung evaluiert gemeinsam mit dem Marketing-Team verschiedene Anbieter. Die zentralen Kriterien sind die Einhaltung der DSGVO, eine einfache Implementierung zur Minimierung des internen

Wartungsaufwands sowie die Skalierbarkeit für zukünftige Anwendungsfälle. Im Anwendungsszenario fällt die Wahl auf eine cloudbasierte und DSGVO-konforme KI-Anwendung, durch die Mitarbeitende auf unterschiedliche LLMs zugreifen können. Als zentrales Ergebnis dieser Phase wird die priorisierte Use-Case-Auflistung finalisiert. Sie enthält als Top-Priorität den Anwendungsfall: „Implementierung einer DSGVO-konformen KI-Anwendung zur Effizienzsteigerung bei der Erstellung von SEO-optimierten Blogbeiträgen und Social-Media-Posts für LinkedIn“ sowie weitere Anwendungsfälle aus dem Vertrieb und dem Produktmanagement. Dieses Dokument dient als verbindliche Entscheidungsgrundlage und leitet den Prozess in die nachfolgende Phase über.

5.6.5 Anwendung auf Prozessphase 3: Prototyping oder Pilotierung

Nach der Konzeptionierung und Planung liegt der Fokus auf der praktischen Erprobung des Anwendungsfalls. Somit zielt die Phase der Pilotierung darauf ab, den Nutzen der KI-Anwendung in einem kontrollierten Rahmen zu testen und Erkenntnisse für die weitere Implementierung sowie die spätere Skalierung zu gewinnen. Im vorliegenden Anwendungsszenario entscheidet sich die Arbeitsgruppe gegen eine ressourcenintensive Eigenentwicklung. Stattdessen wird der Erwerb einer vorerst limitierten Anzahl von Lizenzen für die in der zweiten Phase evaluierte, DSGVO-konforme KI-Anwendung umgesetzt, um einen schnellen und kosteneffizienten Einstieg in die Pilotierungsphase zu ermöglichen. Im Anschluss daran wird ein Pilotprojekt mit einer klar definierten Zielgruppe und einem festen Zeitrahmen initiiert. Als Pilotgruppe werden drei Personen des Marketing-Teams ausgewählt. Ziel des Pilotprojektes ist die Erstellung von Entwürfen für zwei SEO-optimierte Blogbeiträge und zehn LinkedIn-Posts, um die technische Umsetzbarkeit und den organisationalen Nutzen zu überprüfen sowie Daten für die Wirtschaftlichkeitsanalyse aus der ersten Phase zu sammeln.

Während des Pilotprojekts erfolgt die kontinuierliche Validierung des Anwendungsfalls, die sowohl technische Leistungsdaten als auch qualitatives Feedback von Nutzer*innen umfasst. Es wird die Zeit gemessen, die für die Erstellung eines Textentwurfs mit der KI-Anwendung benötigt wird, und mit dem bisherigen manuellen Aufwand verglichen. Parallel dazu wird in wöchentlichen Feedback-Gesprächen die wahrgenommene Qualität der Texte, die Benutzerfreundlichkeit der Plattform und die allgemeine Zufriedenheit hinsichtlich der Nutzbarkeit der KI-Anwendung erfasst. Die Ergebnisse dieser Feedbackschleifen fließen direkt in

die Optimierung ein. Die Pilotgruppe stellt fest, dass die generierten Texte durch eine Anpassung der Eingabeaufforderungen (Prompts) präziser auf die Tonalität des Unternehmens ausgerichtet werden können. Daraufhin entwickelt das Team einen ersten internen Prompt-Leitfaden, der die Qualität der Ergebnisse verbessert. Dieser Lernprozess unterstreicht den agilen Charakter des Implementierungsframeworks. Zum Abschluss der Phase werden alle Erkenntnisse systematisch dokumentiert. Das zentrale Ergebnis ist eine funktionsfähige KI-Anwendung für die Content-Erstellung im Marketing sowie ein dazugehöriger Validierungsbericht, dessen Kernerkenntnisse innerhalb der Use-Case-Auflistung mit einfließen.

Der Bericht bestätigt den erwarteten Nutzen durch eine nachgewiesene Reduktion des Zeitaufwands für die Texterstellung, dokumentiert das positive Feedback der Pilotgruppe und enthält den erarbeiteten Prompt-Leitfaden. Zudem wird eine klare Empfehlung formuliert, die Lösung auf die gesamte Marketingabteilung auszurollen und weitere Anwendungsfälle im Vertrieb und Produktmanagement zu realisieren. Damit ist die Grundlage für die nachfolgende Phase geschaffen.

5.6.6 Anwendung auf Prozessphase 4: Integration und Rollout

Nach der erfolgreichen Pilotierung beginnt die Phase der Integration und des Rollouts. Ihr Ziel ist es, die KI-Anwendung von einer isolierten Testanwendung in die Arbeitsprozesse zu überführen und die Nutzung auf eine breitere Personengruppe auszuweiten. Basierend auf der positiven Empfehlung aus dem Validierungsbericht fällt die Entscheidung, die Nutzung der KI-Anwendung auf die gesamte Marketingabteilung auszurollen. Dies schließt nun auch die übrigen Mitarbeitenden aus der Marketingabteilung mit ein, um Synergien zwischen Text- und Bilderstellung zu fördern und ein einheitliches Verständnis für die neuen technologischen Möglichkeiten innerhalb der gesamten Abteilung zu schaffen. Zu diesem Zweck wird das Lizenzkontingent für die KI-Anwendung erhöht.

Parallel dazu erfolgt die Umsetzung begleitender organisatorischer Maßnahmen, die für die Akzeptanz und den nachhaltigen Erfolg entscheidend sind. Im Mittelpunkt steht eine gezielte Schulung der noch unerfahrenen Mitarbeitenden, die durch Schlüsselpersonen des Pilotprojekts in Form eines KI-Trainings erfolgt. In diesem Training wird nicht nur die grundlegende Bedienung der Plattform erläutert, sondern vor allem der in der dritten Phase entwickelte und nun verfeinerte Prompt-Leitfaden vorgestellt. Eine transparente Kommunikationsstrategie begleitet diesen Prozess. Die positiven Ergebnisse des Pilotprojekts, insbesondere die

nachgewiesene Effizienzsteigerung, werden zudem der Vertriebsabteilung und dem Produktmanagement präsentiert, um das Vertrauen in die KI-Anwendung zu forcieren und weitere Implementierungsprojekte anzustoßen. Letztlich wird die technische Integration in bestehende IT-Systeme pragmatisch gestaltet. Anstelle einer komplexen API-Anbindung wird die KI-Anwendung als Standardwerkzeug in den täglichen Content-Erstellungsprozess integriert. Der Workflow wird klar definiert: Textentwürfe werden auf der KI-Anwendung generiert, anschließend in Microsoft-Office-Anwendungen weiterbearbeitet und final über die bestehenden Kanäle (Shopware-Blog, LinkedIn) publiziert.

Als zentrales Ergebnis dieser Phase steht am Ende eine KI-Anwendung, die von der gesamten Marketingabteilung aktiv genutzt wird. Flankiert wird dies durch eine umfassende Test- und Schulungsdokumentation. Diese besteht aus dem Validierungsbericht der Pilotphase, der als Testdokumentation die Wirksamkeit belegt, sowie dem finalisierten Prompt-Leitfaden, der als offizielle Schulungs- und Anwendungsrichtlinie dient. Mit dem erfolgreichen abteilungsinternen Rollout ist die Basis für die letzte Phase des Frameworks gelegt.

5.6.7 Anwendung auf Prozessphase 5: Evaluation und Weiterentwicklung

Die letzte Phase ist als fortlaufender, lernorientierter Steuerungsprozess konzipiert. Sie dient nicht dem Abschluss des Projekts, sondern der Messung des Erfolgs und der strategischen Entscheidung über das weitere Vorgehen, wodurch der zyklische Charakter des Frameworks hervorgehoben wird.

Im Anschluss an den erfolgreichen Rollout in der Marketingabteilung wird ein strukturierter Monitoring-Prozess etabliert. Der Head of Marketing führt wöchentliche Gesprächsrunden mit dem Marketing-Team durch, um die Nutzungsintensität, die Akzeptanz der neuen Arbeitsweise und die Stabilität der KI-Anwendung kontinuierlich zu überprüfen. Dabei wird das Feedback der Nutzer*innen systematisch erfasst, um mögliche Problemstellungen oder neue Ideen frühzeitig zu identifizieren. Parallel dazu erfolgt die Durchführung einer Erfolgsmessung, die direkt an die innerhalb der zweiten Phase definierten KPI der Wirtschaftlichkeitsanalyse anknüpft. Es wird eine Messung des Time-to-Value vorgenommen, indem die tatsächliche Zeitersparnis bei der Content-Erstellung den Lizenzkosten gegenübergestellt wird. Die Analyse bestätigt, dass die innerhalb der dritten Phase gemessene Effizienzsteigerung auch nach dem abteilungsinternen Rollout beibehalten wird, wodurch der Anwendungsfall validiert sowie der Mehrwert der Implementierung beziffert wird.

Auf Basis der positiven Evaluationsergebnisse wird eine evidenzbasierte Entscheidung über die nächsten Schritte getroffen. Anstatt den Prozess als abgeschlossen anzusehen, wird eine Skalierung auf weitere Fachbereiche angestrebt. Da im Stakeholder-Meeting (Phase 2) bereits der Bedarf des Vertriebs an zielgruppenspezifischen Inhalten deutlich wurde, fällt die Entscheidung unter Berücksichtigung der Priorisierung der Use-Case-Auflistung auf diesen Anwendungsfall. Demzufolge wird die Implementierung der KI-Anwendung als nächstes im Vertriebsteam angestoßen und behält weiterhin die höchste Priorisierung innerhalb der Use-Case-Auflistung. Bedingt durch den rekurrierenden Charakter des Frameworks kann die Implementierung in Abhängigkeit der Gegebenheiten sowohl innerhalb der zweiten Prozessphase als auch in der dritten begonnen werden. Ergänzend dazu wird hervorgehoben, dass im Laufe des Implementierungsprozesses neu identifizierte Problemstellungen oder Chancen eine Rückkehr zur ersten Prozessphase rechtfertigen. Letztlich ist das Ergebnis der fünften Phase ein umfassender Evaluationsbericht, der den Erfolg der initialen Implementierung dokumentiert, sowie die aktualisierte Use-Case-Auflistung, die die strategische Weiterentwicklung des KI-Einsatzes im Unternehmen sicherstellt.

Mit der theoretischen Adaption des Implementierungsframeworks schließt die Ergebnisdarstellung ab. Das folgende Kapitel 6 widmet sich der abschließenden Diskussion und Einordnung der gewonnenen Erkenntnisse, beantwortet die Forschungsfragen und leitet daraus Implikationen für Wissenschaft und Praxis ab.

6 DISKUSSION DER UNTERSUCHUNGSERGEBNISSE

6.1 Zentrale Ergebnisse der Forschungsarbeit und Beantwortung der Forschungsfragen

Ziel dieser Forschungsarbeit war die Entwicklung eines Implementierungsframeworks für den Einsatz generativer KI in mittelständischen Unternehmen. Als methodische Grundlage diente ein dreistufiger Forschungsprozess im Rahmen eines qualitativ-explorativen Ansatzes, der Expert*inneninterviews, die darauf aufbauende Entwicklung des Frameworks und dessen abschließende Validierung umfasste. Im Folgenden werden die drei zentralen Ergebnisse dieser Untersuchung dargelegt und zur Beantwortung der Forschungsfragen herangezogen.

Das erste zentrale Ergebnis ist der Entwurf eines Implementierungsframeworks, das den Prozess der Einführung von generativer KI im deutschen Mittelstand in fünf grundlegende Phasen unterteilt: (1) Identifikation von Problemen sowie Chancen und Kontextanalyse, (2) Konzeptionierung und Planung, (3) Prototyping oder Pilotierung, (4) Integration und Rollout sowie (5) Evaluation und Weiterentwicklung. Darauf aufbauend ist das zweite zentrale Ergebnis die Konzeption des Frameworks als zyklischer, adaptiver Prozess. Diese Ausrichtung resultiert aus der Erkenntnis, dass ein rein lineares Vorgehen der dynamischen Unternehmensrealität nicht gerecht wird. Die sich daraus ergebende finale Version ermöglicht daher durch explizite Validierungsschleifen und die Möglichkeit von Phasen-Sprüngen ein kontinuierliches organisationales Lernen sowie eine hohe prozessuale Flexibilität. Als letztes zentrales Ergebnis wurden drei strategische Voraussetzungen identifiziert, die den Implementierungsprozess rahmen. Diese umfassen eine symbiotische Steuerungslogik, welche zentrale Top-down-Vorgaben mit dezentralen Bottom-up-Initiativen verbindet, eine fundierte Technologie- und Datenstrategie als Basis für Skalierbarkeit und Sicherheit sowie die kontinuierliche Mitarbeitendenbefähigung, die sich als unerlässlich für eine nachhaltige Akzeptanz und den effektiven Nutzen der Technologie erweist. Vor dem Hintergrund dieser zentralen Ergebnisse werden nachfolgend die zugrunde gelegten Forschungsfragen beantwortet.

(LF): Wie kann sich der Implementierungsprozess generativer KI für deutsche KMU ausgestalten, und welche strategischen Ansätze sowie zugrunde liegenden Basistechnologien können hierbei Anwendung finden?

Der Implementierungsprozess generativer KI in deutschen Unternehmen gestaltet sich als ein iterativer, fünfphasiger Prozess, der sich von der initialen Problem- und Chancenidentifikation bis zur kontinuierlichen Evaluation und Weiterentwicklung erstreckt. Dieser Prozess ist nicht als starrer, linearer Ablauf zu verstehen, sondern manifestiert sich als ein adaptiver Zyklus mit rekursiven Schleifen. Als strategischer Ansatz hat sich eine hybride Steuerungslogik herausgestellt, die zentrale, rahmensetzende Vorgaben mit dezentraler, operativer Initiative verbindet. Bei den Basistechnologien konnte keine Dominanz eines universellen Standards identifiziert werden. Stattdessen verfolgen Unternehmen einen modularen Ansatz, bei dem offene Systemarchitekturen je nach Anwendungsfall, Datenschutzanforderungen und internen Kompetenzen flexibel kombiniert werden.

(EF1): Wie können deutsche KMU bei der Implementierung von generativer KI vorgehen, und welche Schritte charakterisieren diesen Prozess?

Deutsche KMU können bei der Implementierung dem entwickelten, fünfphasigen Implementierungsframework folgen. Der Prozess wird durch folgende Schritte charakterisiert: Eine systematische Analyse der Ausgangslage (Phase 1) und eine detaillierte Planung sowie Priorisierung und Depriorisierung von Anwendungsfällen unter partizipativer Einbindung relevanter Stakeholder (Phase 2) sind erforderlich. Zudem ist die agile Erprobung mittels eines MVP in einem kontrollierten Umfeld notwendig (Phase 3). Es folgt ein schrittweiser, von Kommunikations- und Schulungsmaßnahmen begleiteter Rollout (Phase 4) sowie eine kontinuierliche Erfolgsmessung und strategische Weiterentwicklung (Phase 5).

(EF2): Welche strategischen Ansätze können deutsche KMU zur Implementierung von generativer KI verfolgen?

Unternehmen können einen hybriden Strategieansatz verfolgen, der geplante und emergente Elemente vereint. Anstelle eines rigiden Masterplans dient eine übergeordnete KI-Roadmap als flexibler Orientierungsrahmen. Die Steuerung erfolgt durch eine symbiotische Logik, die Top-down-Elemente (z. B. Ressourcenzuweisung, Governance) mit Bottom-up-Prozessen (z. B. Identifikation von Anwendungsfällen) verzahnt. Die Kultivierung einer KI-affinen und lernbereiten Unternehmenskultur ist dabei ein integraler Bestandteil der strategischen Umsetzung.

(EF3): Welche Basistechnologien können von deutschen KMU zur Implementierung von generativer KI herangezogen werden?

Die Auswahl der Basistechnologien ist stets anwendungsfall-spezifisch und kontextabhängig. Unternehmen können eine Kombination aus Cloud-basierten Diensten, Self-Hosting-Optionen und Middleware-Lösungen nutzen, um technologische Flexibilität und Anbieterunabhängigkeit zu sichern. Die Integration in bestehende Systemlandschaften erfolgt vorrangig über APIs. Es zeigt sich eine klare Tendenz zu modularen und offenen Architekturen, wobei die Entscheidung zwischen ganzheitlichen Plattformen und spezialisierten Einzel-Tools auf Basis der internen Kompetenzen und spezifischen Datenschutzanforderungen getroffen wird.

(EF4): Welche Bewertungskriterien können deutsche KMU anwenden, um den Erfolg der Implementierung zu beurteilen?

Zur Erfolgsbeurteilung kann ein mehrdimensionales Bewertungsmodell angewendet werden. Anstelle einer singulären Kennzahl wird eine Kombination aus technischen (z. B. Systemverfügbarkeit), ökonomischen (z. B. ROI), prozessualen (z. B. Effizienzgewinne) und nutzerbezogenen (z. B. Akzeptanz) Kriterien etabliert. Die Erfolgsmessung ist dabei ein dynamischer Prozess, der im Projektverlauf flexibel angepasst wird und sowohl quantitative Metriken als auch qualitatives Feedback integriert.

(EF5): Wie können deutsche KMU ihre KI-Roadmap formulieren und welche fortführenden Implementierungsmaßnahmen können sie hieraus ableiten?

Die KI-Roadmap wird als ein adaptives, strategisches Steuerungsinstrument und nicht als statischer Zeitplan formuliert. Ihre Entwicklung beginnt mit einer initialen Standortbestimmung und wird durch Erkenntnisse aus Pilotprojekten iterativ fortgeschrieben. Fortführende Maßnahmen werden auf Basis der Evaluationsergebnisse (Phase 5) abgeleitet. Diese umfassen die Skalierung erfolgreicher Anwendungen, die funktionale Erweiterung bestehender Lösungen oder die Initiierung neuer Projekte aus einer priorisierten Use-Case-Auflistung. Hierdurch wird der zyklische Charakter des Implementierungsprozesses erneut angestoßen und institutionalisiert.

Mit der Zusammenfassung der zentralen Ergebnisse und der Beantwortung der Forschungsfragen im vorangegangenen Kapitel wird nachfolgend die Neuartigkeit der wissenschaftlichen Ergebnisse sowie der wissenschaftliche Beitrag dargelegt.

6.2 Neue wissenschaftliche Ergebnisse und Beitrag der Forschungsarbeit

Die vorliegende Forschungsarbeit leistet einen wissenschaftlichen Beitrag, der sich nicht auf eine einzelne Dimension beschränkt, sondern aus der Verbindung von theoretischer Fundierung, empirischer Erkenntnisgewinnung und methodischer Konsequenz entsteht. Im Zentrum steht ein Implementierungsframework, das erstmals den Einführungsprozess generativer KI im deutschen Mittelstand systematisch beschreibbar und handhabbar macht. Die Neuheit dieses Beitrags erschließt sich dabei nicht allein aus der Existenz des Frameworks, sondern aus dem, was es konzeptuell leistet – und was bestehende Modelle strukturell nicht leisten können.

Bestehende Ansätze – ob das plan-getriebene Wasserfallmodell als Prozessmodell, agile Methoden wie Scrum oder Kanban, oder das datenorientierte CRISP-DM-Framework – wurden für Kontexte entwickelt, in denen Zielzustände definierbar und Prozesse technisch steuerbar sind. Sie adressieren weder die spezifischen Ressourcenrestriktionen des Mittelstands noch die kulturellen, organisationalen und strategischen Dimensionen, die eine erfolgreiche KI-Einführung konstituieren. Das erklärt, warum in der Praxis häufig auf Ansätze zurückgegriffen wird, die für den vorliegenden Kontext strukturell ungeeignet sind – und warum ein spezifisches Framework für diesen Kontext bis dato nicht existierte.

Genau hier liegt der Kern des wissenschaftlichen Beitrags dieser Arbeit: Die Einführung generativer KI unterscheidet sich grundlegend von klassischen IT-Implementierungsprojekten. Während die Einführung eines CRM-Systems, einer Cloud-Infrastruktur oder computergesteuerter Prozesse einen definierten Zielzustand kennt und technisch abgeschlossen werden kann, ist generative KI kein statisches Werkzeug, sondern ein dynamisches System, das kontinuierliches Lernen, Anpassung und organisationale Reflexionsfähigkeit erfordert. Die Technologie verändert nicht nur Prozesse, sondern Rollenbilder, Entscheidungslogiken und das Verhältnis der Mitarbeitenden zu ihrer eigenen Arbeit. Diese kulturelle und organisationale Dimension ist nicht nachgelagert – sie ist konstitutiv für den Einführungserfolg. Die empirischen Ergebnisse dieser Arbeit, gewonnen aus 39 Expert*inneninterviews sowie der Analyse von 32 Podcastepisoden, belegen konsistent, dass das Scheitern von KI-Initiativen im Mittelstand weniger auf technische als auf strukturelle, kommunikative und kulturelle Defizite zurückzuführen ist. Diese Erkenntnis ist neu – und sie ist handlungsleitend.

Das entwickelte Framework trägt diesem Ergebnis Rechnung, indem es eine iterativ-zyklische Prozesslogik mit einer symbiotischen Steuerungsarchitektur verbindet. Es gliedert den

Einführungsprozess in aufeinander aufbauende, rückkopplungsfähige Phasen und verankert dabei Mitarbeitendenbefähigung, Change Management und strategische Führungsverantwortung als integrale Bestandteile – nicht als optionale Ergänzungen. Der wissenschaftliche Mehrwert dieser Architektur liegt nicht allein in ihrer Vollständigkeit, sondern in der konzeptuellen Entscheidung, prozessbeschreibende und prozessbegleitende Dimensionen systematisch zu trennen und gleichzeitig in einem integrierten Rahmen zusammenzuführen. Damit wird erstmals ein Bezugsrahmen geschaffen, der den Implementierungsprozess generativer KI im Mittelstand nicht als lineares Projektvorhaben, sondern als organisationales Transformationsgeschehen begreift und beschreibbar macht. Die nachfolgende Tabelle 19 fasst die wissenschaftlichen Beiträge dieser Arbeit dimensionsbezogen zusammen und stellt deren Neuartigkeit im Verhältnis zum bestehenden Forschungsstand explizit gegenüber.

Tabelle 19: Übersicht der wissenschaftlichen Beiträge und neuen wissenschaftlichen Ergebnisse

Nr.	Beitragsdimension	Wissenschaftlicher Beitrag	Neuartigkeit der Ergebnisse
1	Konzeptuell	Erstmalige Konzeptualisierung der Einführung generativer KI im Mittelstand als organisationales Transformationsgeschehen – nicht als abgeschlossenes IT-Projekt mit definierbarem Endzustand	Bestehende Modelle konzipieren Implementierung als technisch-linearen Prozess; diese Arbeit überwindet diese Konzeption grundlegend und schafft damit einen neuen konzeptuellen Bezugsrahmen für den Mittelstandskontext
2	Konzeptuell	Entwicklung einer Framework-Architektur: systematische Trennung und gleichzeitige Integration von prozessbeschreibenden (5 Phasen) und prozessbegleitenden Dimensionen (4 Steuerungsdimensionen)	Keine bestehende Methodik verbindet beide Ebenen für den KMU-Kontext mit generativer KI; die Steuerungsarchitektur schließt damit eine strukturelle Lücke, die in der Praxis konsistent als Scheiternsfaktor identifiziert wurde
3	Empirisch	Nachweis, dass das Scheitern von KI-Initiativen im Mittelstand primär auf strukturelle, kommunikative und kulturelle Defizite zurückzuführen ist – belegt durch 39 Expert*inneninterviews und die Analyse von 32 Podcastepisoden	Bisherige Forschung fokussiert mehrheitlich technische und finanzielle Barrieren; die kulturelle und organisationale Dimension wird erstmals als konstitutiver – nicht nachgelagerter – Erfolgsfaktor empirisch nachgewiesen
4	Praktisch	Kontextspezifisches Implementierungsframework mit phasenbezogenen Artefakten (u. a. Problem- & Chancen-Canvas, MVP-Metriken, Evaluationsreports) sowie strukturell verankertem Change Management und Mitarbeitendenbefähigung	Erstmals existiert ein vollständig auf den deutschen Mittelstand ausgerichtetes, empirisch fundiertes Orientierungsmodell – das organisationale und regulatorische Dimensionen nicht als Ergänzung, sondern als integrale Bestandteile begreift
5	Transferierbarkeit	Theoriebasierte Übertragbarkeit auf KMU mit vergleichbaren Strukturmerkmalen (begrenzte Ressourcen, flache Hierarchien, hohe Inhaberprägung, früher Digitalisierungsreife)grad)	Das Framework erhebt keinen Anspruch universeller Gültigkeit, legt jedoch ein empirisch gesättigtes Fundament für quantitative Folgestudien, internationale Vergleiche und branchenspezifische Adaptionen

Quelle: Eigene Darstellung

Das Framework ist auf den deutschen Mittelstand ausgerichtet und kontextspezifisch verankert. Es erhebt keinen Anspruch universeller Gültigkeit, da dies im Rahmen qualitativ-explorativer Forschung methodologisch nicht haltbar wäre. Gleichwohl ist seine konzeptuelle Logik auf KMU übertragbar, die vergleichbare strukturelle Merkmale aufweisen, darunter begrenzte Ressourcen, flache Hierarchien, hohe Inhaberprägung sowie ein früher Digitalisierungsreifegrad. Unternehmen, die diesen Kontext nicht teilen, werden situative Anpassungen vornehmen müssen, was nicht als Einschränkung, sondern als Ausdruck der Anschlussfähigkeit des Frameworks zu verstehen ist. Die vorliegende Arbeit legt damit ein erstes empirisch gesättigtes Fundament, auf dem quantitative Folgestudien, internationale Vergleiche und kontextspezifische Adaptionen aufbauen können.

Mit der Darlegung des wissenschaftlichen Beitrags und der Neuartigkeit der Forschungsergebnisse schließt dieses Kapitel ab. Als logische Konsequenz aus der Entwicklung und Validierung des Implementierungsframeworks richtet sich der Blick nun auf die direkten Implikationen für die Unternehmenspraxis. Das nachfolgende Kapitel überführt die zentralen Ergebnisse in anwendbare Handlungsempfehlungen, um Entscheidungsträgern im Mittelstand eine konkrete Orientierung zu bieten.

6.3 Handlungsempfehlungen für die Unternehmenspraxis

Aufbauend auf der Finalversion des Implementierungsframeworks werden in diesem Kapitel Handlungsempfehlungen für die Unternehmenspraxis im deutschen Mittelstand formuliert. Ziel ist es, den Transfer der wissenschaftlichen Ergebnisse in einen anwendbaren Orientierungsrahmen zu gewährleisten, der das Management, aber auch Führungskräfte und Projektverantwortliche bei der Einführung generativer KI unterstützt. Die Empfehlungen gliedern sich somit in strategische Empfehlungen, die sich primär an das Management richten, und operative Empfehlungen, die sich an den Phasen des Implementierungsframeworks orientieren und richtungsweisend für Führungskräfte und Projektverantwortliche sind.

6.3.1 Strategische Handlungsempfehlungen entlang des Implementierungsframeworks

Auf strategischer Ebene wird empfohlen, die notwendigen Rahmenbedingungen für eine erfolgreiche Implementierung zu schaffen. Hierzu zählt insbesondere die Etablierung einer symbiotischen Steuerungslogik, bei der eine reine Top-down- oder Bottom-up-Vorgehensweise vermieden werden sollte. Die Aufgabe des Managements besteht darin, die strategi-

sche Vision, die Legitimation und das Budget bereitzustellen. Gleichzeitig werden die Mitarbeitenden aktiv befähigt und ermutigt, aus ihrem operativen Alltag heraus konkrete Anwendungsfälle zu identifizieren. Eine wesentliche Voraussetzung hierfür ist, dass die Mitarbeitendenbefähigung nicht als einmalige Maßnahme, sondern als eine dauerhafte strategische Aufgabe verstanden wird. Hierfür eignen sich niedrigschwellige Formate wie „Prompt-Leitfäden“ oder die Benennung von „KI-Champions“, die ihr Wissen effizient im Unternehmen streuen und forcieren. Ergänzend dazu ist die Entwicklung einer vorgelagert-pragmatischen Technologie- und Datenstrategie erforderlich. Diese sollte durch klare Leitplanken – etwa zur Nutzung von Cloud-Diensten oder zur Identifikation interner Datenquellen – die notwendige Orientierung geben, ohne eine Handlungslähmung im Projektverlauf auszulösen.

6.3.2 Operative Handlungsempfehlungen entlang des Implementierungsframeworks

Die operativen Handlungsempfehlungen orientieren sich an den Phasen des entwickelten Implementierungsframeworks. Für die erste Phase der Identifikation von Problemen sowie Chancen und der Kontextanalyse wird empfohlen, den Fokus über die reine Problemlösung hinaus auf die proaktive Erkennung von Chancen zu erweitern. Um hierbei Verbindlichkeit zu schaffen, sollten die Ergebnisse, beispielsweise mittels eines „Problem- & Chancen-Canvas“, formalisiert werden. In der nachfolgenden zweiten Phase der Konzeptionierung und Planung ist die Durchführung einer ersten pragmatischen Wirtschaftlichkeitsanalyse („AI Economics“) von Bedeutung, um eine initiale Investitionsentscheidung zu ermöglichen. Als kritischster Erfolgsfaktor erweist sich demnach die Priorisierung und Depriorisierung von Anwendungsfällen in einem abteilungsübergreifenden Stakeholder-Meeting, in dem die Anwendungsfälle auf Basis einer Bewertungsmatrix rational bewertet und verbindlich ausgewählt werden.

Die dritte Phase des Prototypings oder der Pilotierung sollte auf die Entwicklung eines skalierbaren MVP anstelle eines POC abzielen. Begleitend dazu ist die systematische Einholung von Feedback der Nutzer*innen durch iterative Feedback-Schleifen essenziell, um die Lösung konsequent am realen Bedarf auszurichten. Für die vierte Phase der Integration und des Rollouts wird die Durchführung einer formalen Testphase mit ausgewählten Beta-Usern vor dem unternehmensweiten Start empfohlen. Ein solcher Schritt minimiert das Risiko technischer Probleme und negativer erster Erfahrungen, die die Akzeptanz nachhaltig beschädigen

können. Dieser Prozess sollte durch eine transparente Kommunikationsstrategie flankiert werden, die den Nutzen der KI-Anwendung klar herausstellt.

Die letzte Phase der Evaluation und Weiterentwicklung sollte durch die Etablierung eines kontinuierlichen Monitorings von zuvor definierten KPIs geprägt sein. Auf Basis der Evaluationsergebnisse ist eine bewusste Entscheidung über die nächsten Schritte zu treffen. Hierzu gehört die Aktualisierung der Use-Case-Auflistung und die Entscheidung, ob eine Anwendung skaliert, funktional erweitert oder sogar zurückgebaut wird. Dadurch wird sichergestellt, dass die Implementierung ein lernender, zyklischer Prozess bleibt.

6.4 Reflexion der Forschungsmethodik

Die kritische Auseinandersetzung des Autors mit dem gewählten methodischen Vorgehen ist essenziell, um die Aussagekraft und Einordnung der Forschungsergebnisse angemessen bewerten zu können. Im Folgenden wird dargelegt, wie die dreistufige Forschungsstruktur im Rahmen des qualitativ-explorativen Ansatzes dazu beigetragen hat, die in der Einleitung herausgearbeiteten Forschungslücken systematisch zu adressieren. Der explorative Charakter der Expert*inneninterviews ermöglichte es, tiefe Einblicke in ein dynamisches und noch wenig erforschtes Praxisfeld zu gewinnen. Die anschließende Entwicklung des Implementierungsframeworks stellte sicher, dass die empirischen Erkenntnisse in einen strukturierten, anwendbaren Orientierungsrahmen überführt wurden. Die finale Validierungsphase diente wiederum dazu, die Praxisrelevanz und Plausibilität des entwickelten Frameworks zu gewährleisten und dieses zu präzisieren.

Gleichwohl unterliegt das gewählte Vorgehen inhärenten Herausforderungen, die in Kapitel 4.5.2.4 methodisch reflektiert wurden und an dieser Stelle in ihrer konzeptionellen Konsequenz für das entwickelte Framework einzuordnen sind. Die erste Herausforderung betrifft die qualitative Natur der Datenerhebung. Die Erkenntnisse basieren auf 39 Expert*inneninterviews, deren Umfang sich am Prinzip der theoretischen Sättigung orientierte und damit methodisch begründet ist. Eine statistische Generalisierbarkeit wurde dabei bewusst nicht angestrebt (Kapitel 4.5.2.4). Eine zweite Herausforderung ergibt sich aus der selektiven Auswahl der Stichprobe. Es ist anzunehmen, dass vorwiegend innovations- und KI-affine Expert*innen an der Studie teilgenommen haben, was zu einer tendenziell optimistischen Darstellung der Implementierungspraktiken führen könnte. Eine dritte Herausforderung liegt in der potenziellen Subjektivität des Autors bei der Interpretation der qualitativen Daten. Dieser

potenziellen Verzerrung wurde jedoch durch den Einsatz von Validierungsstrategien, insbesondere durch das Member Checking in der dritten Forschungsphase, entgegengewirkt, indem die interpretierten Ergebnisse den befragten Expert*innen zur Überprüfung zurückgespiegelt wurden.

Darüber hinaus ist die ausgeprägte strukturelle Heterogenität des KMU-Sektors in ihrer Konsequenz für das entwickelte Implementierungsframework gesondert einzuordnen. Während die methodischen Implikationen dieser Heterogenität in Kapitel 4.5.2.4 dargelegt wurden, ist an dieser Stelle die konzeptionell-inhaltliche Dimension gesondert zu reflektieren: Das entwickelte Framework bewegt sich bewusst auf einem generischen Abstraktionsniveau, das eine branchenübergreifende Anwendbarkeit im deutschen Mittelstand ermöglicht. Dieses Abstraktionsniveau ist jedoch nicht als Vereinfachung zu verstehen, sondern als konzeptionelle Notwendigkeit angesichts der tatsächlichen Komplexität des Untersuchungsfeldes. Das Spannungsfeld zwischen dieser generischen Rahmung und der strukturellen Heterogenität mittelständischer Unternehmen – hinsichtlich Unternehmensgröße, Digitalisierungsgrad, Kundenfokussierung sowie strategischem Mindset – ist dabei kein Konstruktionsfehler des Frameworks, sondern ein inhärentes Merkmal jedes praxisorientierten Orientierungsrahmens, der kontextübergreifende Gültigkeit beansprucht. Die situative Konkretisierung des Frameworks im jeweiligen Anwendungskontext ist damit nicht Ausdruck seiner Unvollständigkeit, sondern Bedingung seiner wissenschaftlich fundierten Praxistauglichkeit. Zugleich schafft das gewählte Abstraktionsniveau genau jene konzeptionelle Grundlage, auf der kontextspezifische Anpassungen und weiterführende Forschungsarbeiten systematisch aufbauen können.

Im Folgenden werden die angewandten qualitativen Gütekriterien, die zur Begegnung dieser Limitationen berücksichtigt wurden, detailliert dargelegt. Dabei wurde die Transparenz und Nachvollziehbarkeit (Kapitel 4.5.2.1) des Forschungsprozesses durch eine umfassende Dokumentation aller methodischen Schritte sichergestellt. Dies umfasste die Offenlegung des Auswahlprozesses, die Entwicklung eines strukturierten Kategoriensystems und die Bearbeitung aller Analyseschritte mittels MAXQDA, sodass die Herleitung der Ergebnisse für Dritte nachvollziehbar bleibt. Zur Stärkung der Validität wurde, wie in Kapitel 4.5.2.2 dargelegt, eine methodische Triangulation eingesetzt. Die systematische Kombination verschiedener Datenquellen (Expert*inneninterviews und Podcastfolgen) und die gezielte Anwendung unterschiedlicher Analyseverfahren (qualitative Inhaltsanalyse nach Kuckartz (2018), Framework Analysis) schufen eine robuste empirische Basis. Insbesondere durch die im

Member Checking durchgeführten Validierungsgespräche der dritten Forschungsphase wurde die Plausibilität und argumentative Fundierung der Ergebnisse direkt durch die ausgewählten Expert*innen bestätigt. Die Kohärenz und Transferierbarkeit (Kapitel 4.5.2.3) wurde durch die konsequente Abstimmung aller methodischen Schritte auf Basis des Forschungsziels gewährleistet. Durch die detaillierte Beschreibung des Forschungskontextes (deutscher Mittelstand), der Stichprobe und des finalen Implementierungsframeworks wird die Grundlage dafür geschaffen, dass Praktiker*innen und Forschende die Anwendbarkeit der Ergebnisse auf ihren eigenen spezifischen Kontext selbst beurteilen können.

6.5 Forschungsausblick

Indem die Forschungsarbeit eine zentrale Forschungslücke schließt, legt sie zugleich das Fundament für weiterführende Untersuchungen. Die sich daraus ergebenden Forschungsfelder resultieren sowohl aus den empirischen Erkenntnissen als auch aus der kritischen Reflexion der eigenen Methodik. Ein erstes Forschungsfeld ergibt sich somit aus den organisatorischen und strategischen Rahmenbedingungen. Hierzu zählen weiterführende Untersuchungen wirksamer Change-Management-Strategien im Mittelstandskontext, um Mitarbeiterakzeptanz zu fördern und kulturelle Barrieren abzubauen. Eng damit verbunden ist die Analyse der Mensch-KI-Kooperation, insbesondere welche neuen Rollen und Qualifikationen im KMU-Umfeld entstehen und wie Mensch-Maschine-Teams optimal gestaltet werden. Ferner ist eine wissenschaftliche Auseinandersetzung mit solchen Governance- und Datenschutzkonzepten erforderlich, die den besonderen Kontext von KMU berücksichtigen. Dies schließt die Erarbeitung branchenspezifischer Ethik- und Compliance-Guidelines mit ein.

Ein weiteres Forschungsfeld eröffnet sich durch die Untersuchung kollaborativer Netzwerk- und Ökosystemansätze, bei denen KMU Ressourcen teilen, um KI-Lösungen gemeinsam zu entwickeln. Zudem ist die Messbarkeit des Erfolgs und die Identifikation von Anwendungsfällen zu berücksichtigen. Zukünftige Studien könnten ein KMU-spezifisches Reifegradmodell für generative KI entwickeln, um den Entwicklungsstand von Unternehmen systematisch zu erfassen. Darauf aufbauend ist die Konzeption transparenter Methoden zur Messung des ROI und operativer Effizienzgewinne essenziell. Dies könnte durch eine systematische, branchenspezifische Use-Case-Analyse ergänzt werden, um erfolgversprechende Anwendungen in Kernbranchen wie Fertigung, Handel und Dienstleistungen zu identifizieren und Best Practices abzuleiten.

Ein drittes Forschungsfeld widmet sich der technologischen Weiterentwicklung und deren Integration in Geschäftsprozesse. Hierzu gehört die Untersuchung zur Optimierung von Personalisierung und Kundenerlebnis durch generative KI im Marketing und Vertrieb. Ferner könnten zukünftige Interaktionsformen wie Voice- und AR-Schnittstellen untersucht werden. Einen hierbei besonders innovativen Forschungsstrang stellt die Entwicklung von Architekturen für agentische KI (Agentic AI) dar, in denen KI-Agenten Aufgaben autonom orchestrieren und abarbeiten. In der höchsten Ausbaustufe könnte dies zur Erforschung der autonomen Geschäftsprozess-Orchestrierung führen, bei der Agenten End-to-End-Prozesse selbständig steuern.

Über die genannten Forschungsfelder hinaus ist die internationale Anschlussfähigkeit des Frameworks ein Aspekt, dem künftige Arbeiten verstärkt Rechnung tragen sollten. Die Forschungsarbeit basiert ausschließlich auf Befragungen im deutschen Mittelstand und ist damit bewusst kontextspezifisch angelegt. Der deutsche Mittelstand weist institutionelle, kulturelle und regulatorische Besonderheiten auf, die seine Befunde von KMU-Kontexten anderer Länder unterscheiden können (Mesloh, 2021; Rajaram & Tinguely, 2024). Hierzu zählen die spezifische Förderlandschaft für Digitalisierung und KI, eine hohe regulatorische Sensibilität durch die DSGVO sowie eine ausgeprägte Mittelstandskultur mit langfristigen Eigentümerstrukturen und einer eher konservativen Risikobereitschaft bei technologischen Innovationen (Ibrahim et al., 2024). Diese Faktoren beeinflussen die Adoptionsdynamik und sind nicht ohne Weiteres auf andere nationale Kontexte übertragbar. Gleichwohl ist anzunehmen, dass zentrale Framework-Elemente — insbesondere die phasenlogische Struktur, die Mitarbeitendenbefähigung sowie die symbiotische Steuerungslogik — kontextübergreifend Gültigkeit besitzen, da sie auf strukturellen Eigenschaften von KMU beruhen (Rajaram & Tinguely, 2024). Zukünftige Forschungsarbeiten könnten systematische Ländervergleiche durchführen — etwa mit KMU-Ökosystemen in der Schweiz und Österreich als kulturell nahestehenden Kontexten oder mit stärker divergierenden Rahmenbedingungen in Südeuropa und Südostasien.

Über diese Forschungsfelder hinaus ermöglicht das entwickelte Implementierungsframework die Ableitung konkreter Hypothesen für weiterführende Forschungsarbeiten. Zu berücksichtigen ist, dass qualitativ-explorative Studien ihrem methodologischen Charakter nach hypothesengenerierend sind: Hypothesen entstehen nicht als Ausgangspunkt, sondern als Ergebnis des Forschungsprozesses (Corbin & Strauss, 1990; Döring, 2023; Flick, 2008;

Mayring, 2022). Die nachfolgend formulierten Hypothesen sind dementsprechend als empirisch fundierte Ausgangsannahmen für Anschlussstudien zu verstehen. Tabelle 20 fasst diese zusammen.

Tabelle 20: Übersicht von Hypothesen für weiterführende Forschungsarbeiten

Hypothese Nr.	Formulierung der Hypothesen
1	Mittelständische Unternehmen, die dem fünfphasigen Implementierungsframework folgen, weisen eine höhere Erfolgsrate bei der Einführung generativer KI auf als Unternehmen, die ein ad-hoc Vorgehen wählen.
2	Die Etablierung einer symbiotischen Steuerungslogik (Top-down & Bottom-up) korreliert positiv mit der Akzeptanz von KI-Anwendungen durch die Mitarbeitenden.
3	Ein höherer Grad an kontinuierlicher Mitarbeitendenbefähigung führt zu einer schnelleren und breiteren Adoption von generativen KI-Tools im Unternehmen.
4	Die Anwendung iterativer Feedback-Schleifen zwischen den Implementierungsphasen reduziert die Projektdauer und erhöht die Zufriedenheit der Nutzer*innen im Vergleich zu einem streng linearen Vorgehen.

Quelle: Eigene Darstellung

Die vorgestellten Hypothesen leiten sich direkt aus den qualitativen Erkenntnissen aus Kapitel 5 ab. Sie formalisieren die in den Expert*inneninterviews sowie Validierungsgesprächen hervorgebrachten Wirkungszusammenhänge, um deren statistische Signifikanz in Folgestudien zu prüfen. Konkret zielen sie darauf ab, die Wirksamkeit des fünfphasigen Modells (Hypothese 1), den positiven Einfluss einer symbiotischen Steuerung (Hypothese 2) und kontinuierlichen Befähigung (Hypothese 3) sowie die Effizienz iterativer Prozesse (Hypothese 4) messbar und vergleichbar zu machen. Letztendlich schließt diese Arbeit eine zentrale Forschungslücke, indem sie ein empirisch validiertes Framework für die KI-Implementierung im Mittelstand entwickelt. Sie überführt die qualitativen Erkenntnisse in einen praxisorientierten Handlungsrahmen und legt durch die im Sinne der qualitativen Forschungslogik generierten Hypothesen zugleich den Grundstein für nachfolgende Forschungen. Somit leistet die Dissertation einen entscheidenden Beitrag zur strukturierten Gestaltung des technologischen Wandels in der Unternehmenspraxis.

ZUSAMMENFASSUNG

Vor dem Hintergrund der rasanten Entwicklung generativer KI und deren transformativem Potenzial für die Wirtschaft stehen insbesondere KMU in Deutschland vor einer signifikanten Herausforderung. Während die Technologie das Potenzial birgt, Geschäftsprozesse zu revolutionieren und die Wettbewerbsfähigkeit zu steigern, limitiert eine Kombination aus Ressourcenknappheit, fehlender Fachexpertise und dem Mangel an strukturierten Vorgehensmodellen die erfolgreiche Implementierung im Mittelstand. Diese Diskrepanz zwischen technologischem Potenzial und praktischer Umsetzbarkeit bildete den Ausgangspunkt dieser Forschungsarbeit. Das primäre Ziel war es daher, diese Lücke zu schließen, indem ein wissenschaftlich fundiertes und zugleich praxisorientiertes Implementierungsframework entwickelt wird, das speziell auf die Rahmenbedingungen und Bedürfnisse von KMU zugeschnitten ist. Sekundäre Ziele umfassten die systematische Untersuchung von strategischen Planungsansätzen, relevanten Basistechnologien, Kriterien zur Erfolgsmessung sowie die Ableitung von Empfehlungen für eine nachhaltige KI-Roadmap.

Zur Erreichung dieser Ziele wurde ein qualitativ-explorativer Ansatz gewählt, der einen dreiphasigen Forschungsprozess zur Entwicklung und Validierung des Implementierungsframeworks vorsah. In der ersten Phase wurden zunächst Fachexpert*innen rekrutiert und ihre Expertise mittels eines Scoring-Modells systematisch bewertet. Darauf aufbauend wurden halbstrukturierte Expert*inneninterviews geführt, um tiefgehende Einblicke in die Unternehmenspraxis zu gewinnen. Parallel dazu erfolgte eine Dokumentenanalyse, bei der die Transkripte relevanter Podcastfolgen als zusätzliche Datenquelle herangezogen wurden. Diese Daten bildeten die Grundlage für die zweite Phase. Hier wurden die Erkenntnisse synthetisiert und auf Basis einer methodisch fundierten Kombination aus dem DSR nach Hevner et al. (2004) und dem Conceptual Framework Development nach Jabareen (2009) in einen ersten Entwurf des Implementierungsframeworks überführt. Die dritte und entscheidende Phase umfasste die Validierung dieses Entwurfs durch Validierungsgespräche mit Fachexpert*innen, die den höchsten Expertisescore vorwiesen. Das hierbei gesammelte Feedback ermöglichte eine gezielte Überarbeitung und Finalisierung des Frameworks, wodurch dessen Robustheit, Kohärenz und vor allem dessen praktische Anwendbarkeit sichergestellt wurde. Das zentrale Ergebnis dieser Forschungsarbeit ist ein validiertes, prozessorientiertes Implementierungsframework, das den komplexen Prozess der Einführung generativer KI in fünf aufeinander aufbauende Hauptphasen gliedert: (1) Identifikation von Problemen sowie

Chancen, (2) Konzeptionierung und Planung, (3) Prototyping oder Pilotierung, (4) Integration und Rollout sowie (5) Evaluation und Weiterentwicklung. Das Framework geht über eine rein technische Anleitung hinaus, indem es strategische, technologische, organisatorische und kulturelle Dimensionen integriert. Es liefert konkrete Handlungsempfehlungen und Entscheidungshilfen für jede Phase und adressiert damit direkt die in der Problemstellung identifizierten Unsicherheiten. Die Forschungsergebnisse bestätigen, dass ein isolierter, rein technologiegetriebener Ansatz für KMU nicht zielführend ist. Stattdessen erweist sich ein ganzheitlicher, strategisch verankerter und iterativ validierter Prozess als entscheidender Erfolgsfaktor.

Die Forschungsarbeit leistet somit einen wesentlichen Beitrag zur Schließung einer Forschungslücke an der Schnittstelle von KI-Forschung und Mittelstandsmanagement. Für die Unternehmenspraxis stellt das entwickelte Framework eine wertvolle, direkt anwendbare Ressource dar. Gleichzeitig eröffnen sich aus den gewonnenen Erkenntnissen weiterführende Forschungsperspektiven. Es wird eine quantitative Validierung des Frameworks anhand einer breiteren Stichprobe von KMU empfohlen, um dessen statistische Generalisierbarkeit zu prüfen und potenzielle Korrelationen zwischen der Anwendung des Frameworks und unternehmerischen Erfolgskennzahlen aufzudecken. Darüber hinaus könnten Längsschnittstudien die langfristigen organisationalen Veränderungen nach der Implementierung untersuchen. Zukünftige Arbeiten könnten zudem branchenspezifische Adaptionen des Frameworks entwickeln oder die Auswirkungen neuer technologischer Paradigmen innerhalb der generativen KI auf den Implementierungsprozess erforschen.

ANHANG

Literaturverzeichnis

- Al Naqbi, H., Bahroun, Z., & Ahmed, V. (2024). Enhancing Work Productivity through Generative Artificial Intelligence: A Comprehensive Literature Review. *Sustainability*, 16(3), 1166. <https://doi.org/10.3390/su16031166>
- Aldoseri, A., Al-Khalifa, K. N., & Hamouda, A. M. (2024). Methodological Approach to Assessing the Current State of Organizations for AI-Based Digital Transformation. *Applied System Innovation*, 7(1), 14. <https://doi.org/10.3390/asi7010014>
- Al-Khatib, A. W. (2024). Prioritizing factors for generative artificial intelligence-based innovation adoption in hospitality industry. *Management Decision*. <https://doi.org/10.1108/MD-09-2023-1525>
- Andreoni, M., Lunardi, W. T., Lawton, G., & Thakkar, S. (2024). Enhancing Autonomous System Security and Resilience With Generative AI: A Comprehensive Survey. *IEEE Access*, 12, 109470–109493. <https://doi.org/10.1109/ACCESS.2024.3439363>
- Barcaui, A., & Monat, A. (2023). Who is better in project planning? Generative artificial intelligence or project managers? *Project Leadership and Society*, 4, 100101. <https://doi.org/10.1016/j.plas.2023.100101>
- Barney, J., Wright, M., & Ketchen, D. J. (2001). The resource-based view of the firm: Ten years after 1991. *Journal of Management*, 27(6), 625–641. <https://doi.org/10.1177/014920630102700601>
- Bartelt, C. (2024). Potenzial zur Demokratisierung von Künstlicher Intelligenz im B2B-Marketing. *Marketing Review St. Gallen, Service Management in the Age of AI and Robotics*, (4), 64–71.
- Bartelt, C., & Röser, A. M. (2024a). AI in Finance: Innovative Approaches for Sustainable Business Models. *E-conom*, 13(2), 98–118. <https://doi.org/10.17836/EC.2024.2.007>
- Bartelt, C., & Röser, A. M. (2024b). Artificial intelligence as a catalyst for sustainable business innovation: Perspectives from finance and marketing. *Gazdaság és Társadalom*, 17(2), 37–65. <https://doi.org/10.21637/GT.2024.2.02>
- Bengesi, S., El-Sayed, H., Sarker, K., Houkpati, Y., & Oladunni, T. (2024). *Advancements in Generative AI: A Comprehensive Review of GANs, GPT, Autoencoders, Diffusion Model, and Transformers*.

- Bengesi, S., El-Sayed, H., Sarker, M. K., Houkpati, Y., Irungu, J., & Oladunni, T. (2024). Advancements in Generative AI: A Comprehensive Review of GANs, GPT, Autoencoders, Diffusion Model, and Transformers. *IEEE Access*, *12*, 69812–69837. <https://doi.org/10.1109/ACCESS.2024.3397775>
- Berger, P., & Von Garrel, J. (2024). Diffusion of AI value-driven services in the German manufacturing industries—An empirical examination of value-driven service references classified by the business Model Canvas. *Frontiers in Industrial Engineering*, *2*, 1407367. <https://doi.org/10.3389/fieng.2024.1407367>
- Bettoni, A., Matteri, D., Montini, E., Gładysz, B., & Carpanzano, E. (2021). An AI adoption model for SMEs: A conceptual framework. *IFAC-PapersOnLine*, *54*(1), 702–708. <https://doi.org/10.1016/j.ifacol.2021.08.082>
- Birken, S. A., Wagi, C. R., Peluso, A. G., Kegler, M. C., Baloh, J., Adsul, P., Fernandez, M. E., Masud, M., Huang, T. T.-K., Lee, M., Wangen, M., Nilsen, P., Bender, M., Choy-Brown, M., Ryan, G., Randazzo, A., & Ko, L. K. (2023). Toward a more comprehensive understanding of organizational influences on implementation: The organization theory for implementation science framework. *Frontiers in Health Services*, *3*, 1142598. <https://doi.org/10.3389/frhs.2023.1142598>
- Birt, L., Scott, S., Cavers, D., Campbell, C., & Walter, F. (2016). Member Checking: A Tool to Enhance Trustworthiness or Merely a Nod to Validation? *Qualitative Health Research*, *26*(13), 1802–1811. <https://doi.org/10.1177/1049732316654870>
- Bitkom e. V. (2025). *KI in der deutschen Wirtschaft—Status quo und Ausblick*. https://www.bitkom.org/sites/main/files/2025-09/bitkom-pressekonferenz-ki-unternehmen-charts_1.pdf
- Boaye Belle, A., & Zhao, Y. (2023). Evidence-based decision-making: On the use of systematicity cases to check the compliance of reviews with reporting guidelines such as PRISMA 2020. *Expert Systems with Applications*, *217*, 119569. <https://doi.org/10.1016/j.eswa.2023.119569>
- Bowen, G. A. (2009). Document Analysis as a Qualitative Research Method. *Qualitative Research Journal*, *9*(2), 27–40. <https://doi.org/10.3316/QRJ0902027>
- Campbell, C., Sands, S., Ferraro, C., Tsao, H.-Y. (Jody), & Mavrommatis, A. (2020). From data to action: How marketers can leverage AI. *Business Horizons*, *63*(2), 227–243. <https://doi.org/10.1016/j.bushor.2019.12.002>

- Cao, Y., Li, S., Liu, Y., Yan, Z., Dai, Y., Yu, P. S., & Sun, L. (2023). *A Comprehensive Survey of AI-Generated Content (AIGC): A History of Generative AI from GAN to ChatGPT* (arXiv:2303.04226). arXiv. <https://doi.org/10.48550/arXiv.2303.04226>
- Chen, J., Zhou, W., & Frankwick, G. L. (2023). Firm AI Adoption Intensity and Marketing Performance. *Journal of Computer Information Systems*, 1–18. <https://doi.org/10.1080/08874417.2023.2277751>
- Chen, L., Jiang, M., Jia, F., & Liu, G. (2022). Artificial intelligence adoption in business-to-business marketing: Toward a conceptual framework. *Journal of Business & Industrial Marketing*, (5), 1025–1044. <https://doi.org/10.1108/JBIM-09-2020-0448>
- Chern, E., Su, J., Ma, Y., & Liu, P. (2024). *ANOLE: An Open, Autoregressive, Native Large Multimodal Models for Interleaved Image-Text Generation* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2407.06135>
- Corbin, J., & Strauss, A. (1990). Grounded Theory Research: Procedures, Canons, and Evaluative Criteria. *Qualitative Sociology*, 13(1). <https://research.ebsco.com/linkprocessor/plink?id=7fe4e6d1-a400-370f-994b-147256d0574b>
- Creswell, J. W., Creswell, J. D., Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (Fifth edition). SAGE.
- Creswell, J. W., & Plano Clark, V. L. (2018). *Designing and conducting mixed methods research* (Third edition). Sage.
- Creswell, J. W., & Poth, C. N. (2018). *Qualitative inquiry and research design* (Fourth edition). SAGE.
- Damschroder, L. J., Aron, D. C., Keith, R. E., Kirsh, S. R., Alexander, J. A., & Lowery, J. C. (2009). Fostering implementation of health services research findings into practice: A consolidated framework for advancing implementation science. *Implementation Science*, 4(1), 50. <https://doi.org/10.1186/1748-5908-4-50>
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24–42. <https://doi.org/10.1007/s11747-019-00696-0>
- Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, 13(3), 319. <https://doi.org/10.2307/249008>
- Deloitte. (2024). *The State of Generative AI in the Enterprise: Now decides next* [Quarter one report].
- Dey, P. K., Chowdhury, S., Abadie, A., Vann Yaroson, E., & Sarkar, S. (2024). Artificial intelligence-driven supply chain resilience in Vietnamese manufacturing small- and

- medium-sized enterprises. *International Journal of Production Research*, 62(15), 5417–5456. <https://doi.org/10.1080/00207543.2023.2179859>
- Döring, N. (2023). *Forschungsmethoden und Evaluation in den Sozial- und Humanwissenschaften*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-64762-2>
- Dresing, T., & Pehl, T. (2018). *Praxisbuch Interview, Transkription & Analyse: Anleitungen und Regelsysteme für qualitativ Forschende* (8. Auflage). Eigenverlag.
- Eisenhardt, K. M. (1989). Building Theories from Case Study Research. *The Academy of Management Review*, 14(4), 532. <https://doi.org/10.2307/258557>
- Enshassi, M., Nathan, R. J., Soekmawati, S., Al-Mulali, U., & Ismail, H. (2024). Potentials of artificial intelligence in digital marketing and financial technology for small and medium enterprises. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 13(1), 639. <https://doi.org/10.11591/ijai.v13.i1.pp639-647>
- Fehrenbach, D., Herrando, C., & Martín-De Hoyos, M. J. (2024). Co-Creation with AI in B2B Markets: A Systematic Literature Review. *Sustainability*, 16(18), 8009. <https://doi.org/10.3390/su16188009>
- Feilzer, Y. M. (2010). Doing Mixed Methods Research Pragmatically: Implications for the Rediscovery of Pragmatism as a Research Paradigm. *Journal of Mixed Methods Research*, 4(1), 6–16. <https://doi.org/10.1177/1558689809349691>
- Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2023). Generative AI. *Business & Information Systems Engineering*. <https://doi.org/10.1007/s12599-023-00834-7>
- Fixsen, D., Naoom, S., Blase, K., Friedman, R., & Wallace, F. (2005). Implementation Research: A Synthesis of the Literature Dean L. Fixsen. *The National Implementation Research Network*, 97.
- Flick, U. (Hrsg.). (2008). *Handbuch qualitative Sozialforschung: Grundlagen, Konzepte, Methoden und Anwendungen* (2. Auflage). Beltz, Psychologie-Verl.-Union.
- Flick, U. (2016). *Qualitative Sozialforschung: Eine Einführung* (11. Auflage, Originalausgabe). rowohlt's enzyklopädie im Rowohlt Taschenbuch Verlag.
- Gale, N. K., Heath, G., Cameron, E., Rashid, S., & Redwood, S. (2013). Using the framework method for the analysis of qualitative data in multi-disciplinary health research. *BMC Medical Research Methodology*, 13(1), 117. <https://doi.org/10.1186/1471-2288-13-117>
- Gan, W., Wan, S., & Yu, P. S. (2023). *Model-as-a-Service (MaaS): A Survey* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2311.05804>

- Glaser, B. G., Strauss, A. L., & Hildenbrand, B. (2010). *Grounded theory: Strategien qualitativer Forschung* (A. T. Paul & S. Kaufmann, Übers.; 3., unveränderte Auflage). Verlag Hans Huber.
- Glauner, D. P. (2024). Technical foundations of generative AI models. *Legal Tech - Zeitschrift Für Die Digitale Anwendung - LTZ, Tech & Market Insights*, (1), 24–34.
- Gołąb-Andrzejak, E. (2023). AI-powered Digital Transformation: Tools, Benefits and Challenges for Marketers – Case Study of LPP. *Procedia Computer Science*, 219, 397–404. <https://doi.org/10.1016/j.procs.2023.01.305>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139–144. <https://doi.org/10.1145/3422622>
- Gozalo-Brizuela, R., & Garrido-Merchán, E. C. (2023). *A survey of Generative AI Applications* (arXiv:2306.02781). arXiv. <http://arxiv.org/abs/2306.02781>
- Gregor, S., & Hevner, A. R. (2013). Positioning and Presenting Design Science Research for Maximum Impact1. *MIS Quarterly*, 37(2), 337–355. <https://doi.org/10.25300/MISQ/2013/37.2.01>
- Gualandri, F., & Kuzior, A. (2024). AI Integration and Economic Divides: Analyzing Global AI Strategies. *System Safety: Human - Technical Facility - Environment*, 6(1), 46–53. <https://doi.org/10.2478/czoto-2024-0006>
- Guest, G., Bunce, A., & Johnson, L. (2006). How Many Interviews Are Enough?: An Experiment with Data Saturation and Variability. *Field Methods*, 18(1), 59–82. <https://doi.org/10.1177/1525822X05279903>
- Gupta, V. (2024). An Empirical Evaluation of a Generative Artificial Intelligence Technology Adoption Model from Entrepreneurs' Perspectives. *Systems*, 12(3), 103. <https://doi.org/10.3390/systems12030103>
- Häder, M. (2019). *Empirische Sozialforschung: Eine Einführung* (4. Auflage). Springer VS. <https://doi.org/10.1007/978-3-658-26986-9>
- Haleem, A., Javaid, M., Asim Qadri, M., Pratap Singh, R., & Suman, R. (2022). Artificial intelligence (AI) applications for marketing: A literature-based study. *International Journal of Intelligent Networks*, 3, 119–132. <https://doi.org/10.1016/j.ijin.2022.08.005>

- Haleem, A., Javaid, M., & Singh, R. P. (2022). An era of ChatGPT as a significant futuristic support tool: A study on features, abilities, and challenges. *BenchCouncil Transactions on Benchmarks, Standards and Evaluations*, 2(4), 100089. <https://doi.org/10.1016/j.tbench.2023.100089>
- Han, R., Lam, H. K. S., Zhan, Y., Wang, Y., Dwivedi, Y. K., & Tan, K. H. (2021). Artificial intelligence in business-to-business marketing: A bibliometric analysis of current research status, development and future directions. *Industrial Management & Data Systems*, (12), 2467–2497. <https://doi.org/10.1108/IMDS-05-2021-0300>
- Hansen, H. F., Lillesund, E., Mikalef, P., & Altwaijry, N. (2024). Understanding Artificial Intelligence Diffusion through an AI Capability Maturity Model. *Information Systems Frontiers*. <https://doi.org/10.1007/s10796-024-10528-4>
- He, A.-Z., & Zhang, Y. (2023). AI-powered touch points in the customer journey: A systematic literature review and research agenda. *Journal of Research in Interactive Marketing*, 17(4), 620–639. <https://doi.org/10.1108/JRIM-03-2022-0082>
- Helffferich, C. (2009). *Die Qualität qualitativer Daten: Manual für die Durchführung qualitativer Interviews* (3., überarbeitete Auflage). VS Verlag für Sozialwissenschaften. <https://doi.org/10.1007/978-3-531-91858-7>
- Hevner, March, Park, & Ram. (2004). Design Science in Information Systems Research. *MIS Quarterly*, 28(1), 75. <https://doi.org/10.2307/25148625>
- Holmström, J., & Carroll, N. (2025). How organizations can innovate with generative AI. *Business Horizons*, 68(5), 559–573. <https://doi.org/10.1016/j.bushor.2024.02.010>
- Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50. <https://doi.org/10.1007/s11747-020-00749-9>
- Huseyn, M., Ruiz-Gandara, A., Gonzalez-Abril, L., & Romero, I. (2024). Adoption of Artificial Intelligence in Small and Medium-Sized Enterprises in Spain: The Role of Competences and Skills. *Amfiteatru Economic*, 26(67), 848. <https://doi.org/10.24818/EA/2024/67/848>
- Ibrahim, M. A., Islam, M., & Aga, S. (2024). *Balanced Data Placement for GEMV Acceleration with Processing-In-Memory* (Version 2). arXiv. <https://doi.org/10.48550/ARXIV.2403.20297>
- ifM Bonn. (2024a). *Kennzahlen der KMU nach Definition der EU-Kommission: Deutschland*. Mittelstand im Überblick. <https://www.ifm-bonn.org/statistiken/mittelstand->

- im-ueberblick/kennzahlen-der-kmu-nach-definition-des-ifm-bonn/kennzahlen-deutschland
- ifM Bonn. (2024b). *Volkswirtschaftliche Bedeutung der KMU*. Mittelstand im Überblick. <https://www.ifm-bonn.org/statistiken/mittelstand-im-ueberblick/volkswirtschaftliche-bedeutung-der-kmu/deutschland>
- ifo Institut. (2025). Mehr KI, weniger Jobs? Was Unternehmen in Deutschland erwarten. *ifo Konjunkturperspektive*, (05/2025). <https://www.ifo.de/fakten/2025-06-16/unternehmen-setzen-immer-staerker-auf-kuenstliche-intelligenz>
- Institut der deutschen Wirtschaft. (2025). Künstliche Intelligenz als Wettbewerbsfaktor für die deutsche Wirtschaft. *Wirtschaftliche Untersuchungen, Berichte und Sachverhalte*, (33).
- Jabareen, Y. (2009). Building a Conceptual Framework: Philosophy, Definitions, and Procedure. *International Journal of Qualitative Methods*, 8(4), 49–62. <https://doi.org/10.1177/160940690900800406>
- Kanbach, D. K., Heiduk, L., Blueher, G., Schreiter, M., & Lahmann, A. (2023). The GenAI is out of the bottle: Generative artificial intelligence from a business model innovation perspective. *Review of Managerial Science*. <https://doi.org/10.1007/s11846-023-00696-z>
- Kaplan, R. S., & Norton, D. P. (1996). *The balanced scorecard: Translating strategy into action*. Harvard Business School Press.
- Kapoor, R., & Klueter, T. (2021). Unbundling and Managing Uncertainty Surrounding Emerging Technologies. *Strategy Science*, 6(1), 62–74. <https://doi.org/10.1287/stsc.2020.0118>
- Kislov, R., Pope, C., Martin, G. P., & Wilson, P. M. (2019). Harnessing the power of theorising in implementation science. *Implementation Science*, 14(1), 103, s13012-019-0957–4. <https://doi.org/10.1186/s13012-019-0957-4>
- Kotter, J. P. (1996). *Leading change*. Harvard Business School Press.
- Krüger, W. (2014). *Excellence in change: Wege zur strategischen Erneuerung* (5., überarb. und erw. Aufl.). Springer Gabler.
- Kruse, J. (with Schmieder, C.). (2015). *Qualitative Interviewforschung: Ein integrativer Ansatz* (2., überarbeitete und ergänzte Auflage). Beltz Juventa.
- Kuckartz, U. (2018). *Qualitative Inhaltsanalyse: Methoden, Praxis, Computerunterstützung* (4. Auflage). Beltz Juventa.

- Kühnapfel, J. B. (2021). *Scoring und Nutzwertanalysen: Ein Leitfaden für die Praxis*. Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-34810-6>
- Kumar, A., Nagarajan, G., Surekha, M., Vijai, C., Mohideen, A. S., Dhinakaran, D. P., & Lakshmi, M. R. (2023). The Impact of Chat GPT on E-commerce. *Journal of Harbin Engineering University*, 43(7).
- Kumar, D., & Ratten, V. (2024). Artificial intelligence and family businesses: A systematic literature review. *Journal of Family Business Management*. <https://doi.org/10.1108/JFBM-08-2024-0160>
- Kumar, V., Ashraf, A. R., & Nadeem, W. (2024). AI-powered marketing: What, where, and how? *International Journal of Information Management*, 102783. <https://doi.org/10.1016/j.ijinfomgt.2024.102783>
- Lada, S., Chekima, B., Karim, Mohd. R. A., Fabeil, N. F., Ayub, M. S., Amirul, S. M., Ansar, R., Bouteraa, M., Fook, L. M., & Zaki, H. O. (2023). Determining factors related to artificial intelligence (AI) adoption among Malaysia's small and medium-sized businesses. *Journal of Open Innovation: Technology, Market, and Complexity*, 9(4), 100144. <https://doi.org/10.1016/j.joitmc.2023.100144>
- Lawton, R., Boswell, S., & Crockett Smiee, K. (2023). The GM AI Foundry: A Model for Upskilling SME's in Responsible AI. *2023 IEEE Symposium Series on Computational Intelligence (SSCI)*, 1781–1787. <https://doi.org/10.1109/SSCI52147.2023.10371988>
- Lemos, S. I. C., Ferreira, F. A. F., Zopounidis, C., Galariotis, E., & Ferreira, N. C. M. Q. F. (2022). Artificial intelligence and change management in small and medium-sized enterprises: An analysis of dynamics within adaptation initiatives. *Annals of Operations Research*. <https://doi.org/10.1007/s10479-022-05159-4>
- Lewin, K. (1947). Frontiers in Group Dynamics: Concept, Method and Reality in Social Science; Social Equilibria and Social Change. *Human Relations*, 1(1), 5–41. <https://doi.org/10.1177/001872674700100103>
- Lewis, M. W., & Grimes, A. J. (1999). Metatriangulation: Building Theory from Multiple Paradigms. *The Academy of Management Review*, 24(4), 672. <https://doi.org/10.2307/259348>
- Li, B., Hou, B., Yu, W., Lu, X., & Yang, C. (2017). Applications of artificial intelligence in intelligent manufacturing: A review. *Frontiers of Information Technology & Electronic Engineering*, 18(1), 86–96. <https://doi.org/10.1631/FITEE.1601885>

- Li, Z., Zhang, J., Lin, Q., Xiong, J., Long, Y., Deng, X., Zhang, Y., Liu, X., Huang, M., Xiao, Z., Chen, D., He, J., Li, J., Li, W., Zhang, C., Quan, R., Lu, J., Huang, J., Yuan, X., ... Lu, Q. (2024). *Hunyuan-DiT: A Powerful Multi-Resolution Diffusion Transformer with Fine-Grained Chinese Understanding* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2405.08748>
- Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry* (Nachdr.). Sage.
- Liu, F., Tong, J., Mao, J., Bohn, R., Messina, J., Badger, L., & Leaf, D. (2011). *NIST cloud computing reference architecture* (NIST SP 500-292; S. NIST SP 500-292). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.SP.500-292>
- Luo, R., Li, Y., Chen, L., He, W., Lin, T.-E., Liu, Z., Zhang, L., Song, Z., Xia, X., Liu, T., Yang, M., & Hui, B. (2024). *DEEM: Diffusion Models Serve as the Eyes of Large Language Models for Image Perception* (Version 4). arXiv. <https://doi.org/10.48550/ARXIV.2405.15232>
- Maarouf, H. (2019). Pragmatism as a Supportive Paradigm for the Mixed Research Approach: Conceptualizing the Ontological, Epistemological, and Axiological Stances of Pragmatism. *International Business Research*, 12(9), 1. <https://doi.org/10.5539/ibr.v12n9p1>
- Malterud, K., Siersma, V. D., & Guassora, A. D. (2016). Sample Size in Qualitative Interview Studies: Guided by Information Power. *Qualitative Health Research*, 26(13), 1753–1760. <https://doi.org/10.1177/1049732315617444>
- Mayring, P. (2022). *Qualitative Inhaltsanalyse: Grundlagen und Techniken* (13., überarbeitete Auflage). Beltz.
- Mesloh, M. (2021). Digitale Integration—Chancen für kleine und mittelständische Unternehmen in Deutschland. *Wirtschaftsdienst*, 101(6), 461–465. <https://doi.org/10.1007/s10273-021-2942-1>
- Mey, G., & Mruck, K. (Hrsg.). (2020). *Handbuch Qualitative Forschung in der Psychologie: Band 2: Designs und Verfahren: 2.* (2., erweiterte und überarbeitete Auflage). Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-26887-9>
- Mikalef, P., Conboy, K., & Krogstie, J. (2021). Artificial intelligence as an enabler of B2B marketing: A dynamic capabilities micro-foundations approach. *Industrial Marketing Management*, 98, 80–92. <https://doi.org/10.1016/j.indmarman.2021.08.003>
- Mikalef, P., & Gupta, M. (2021). Artificial intelligence capability: Conceptualization, measurement calibration, and empirical study on its impact on organizational creativity

- and firm performance. *Information & Management*, (3), 103. <https://doi.org/10.1016/j.im.2021.103434>
- Mikalef, P., Islam, N., Parida, V., Singh, H., & Altwaijry, N. (2023). Artificial intelligence (AI) competencies for organizational performance: A B2B marketing capabilities perspective. *Journal of Business Research*, 164, 113. <https://doi.org/10.1016/j.jbusres.2023.113998>
- Mintzberg, H., & Waters, J. A. (1985). Of strategies, deliberate and emergent. *Strategic Management Journal*, 6(3), 257–272. <https://doi.org/10.1002/smj.4250060306>
- Nezameslami, R., Nezameslami, A., Mehdikhani, B., Mosavi-Jarrahi, A., Shahbazi, A., Rahmani, A., Masoudi, A., Yeganegi, M., Akhondzardaini, R., Bahrami, M., Aghili, K., & Neamatzadeh, H. (2025). Adapting PRISMA Guidelines to Enhance Reporting Quality in Genetic Association Studies: A Framework Proposal. *Asian Pacific Journal of Cancer Prevention*, 26(5), 1641–1651. <https://doi.org/10.31557/APJCP.2025.26.5.1641>
- Nilsen, P. (2015). Making sense of implementation theories, models and frameworks. *Implementation Science*, 10(1), 53. <https://doi.org/10.1186/s13012-015-0242-0>
- Oldemeyer, L., Jede, A., & Teuteberg, F. (2024). Investigation of artificial intelligence in SMEs: A systematic review of the state of the art and the main implementation challenges. *Management Review Quarterly*. <https://doi.org/10.1007/s11301-024-00405-4>
- Paaß, G., & Giesselbach, S. (2023). *Foundation Models for Natural Language Processing: Pre-trained Language Models Integrating Media*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-23190-2>
- 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 systematic reviews. *BMJ*, n71. <https://doi.org/10.1136/bmj.n71>
- Page, M. J., Moher, D., 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., McDo-

- nald, S., ... McKenzie, J. E. (2021). PRISMA 2020 explanation and elaboration: Updated guidance and exemplars for reporting systematic reviews. *BMJ*, n160. <https://doi.org/10.1136/bmj.n160>
- Pan, K., Tang, S., Li, J., Fan, Z., Chow, W., Yan, S., Chua, T.-S., Zhuang, Y., & Zhang, H. (2024). *Auto-Encoding Morph-Tokens for Multimodal LLM* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2405.01926>
- Peirce, C. S. (1997). *Pragmatism as a principle and method of right thinking: The 1903 Harvard lectures on pragmatism* (P. A. Turrisi, Hrsg.). State University of New York Press.
- Peres, R. S., Jia, X., Lee, J., Sun, K., Colombo, A. W., & Barata, J. (2020). Industrial Artificial Intelligence in Industry 4.0—Systematic Review, Challenges and Outlook. *IEEE Access*, 8, 220121–220139. <https://doi.org/10.1109/ACCESS.2020.3042874>
- Pettigrew, A. M. (1997). What is a processual analysis? *Scandinavian Journal of Management*, 13(4), 337–348. [https://doi.org/10.1016/S0956-5221\(97\)00020-1](https://doi.org/10.1016/S0956-5221(97)00020-1)
- Prasad Agrawal, K. (2024). Towards Adoption of Generative AI in Organizational Settings. *Journal of Computer Information Systems*, 64(5), 636–651. <https://doi.org/10.1080/08874417.2023.2240744>
- Rädiker, S., & Kuckartz, U. (2019). *Analyse qualitativer Daten mit MAXQDA: Text, Audio und Video*. Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-22095-2>
- Rajaram, K., & Tinguely, P. N. (2024). Generative artificial intelligence in small and medium enterprises: Navigating its promises and challenges. *Business Horizons*, S0007681324000685. <https://doi.org/10.1016/j.bushor.2024.05.008>
- Reichertz, J. (2013). *Die Abduktion in der Qualitativen Sozialforschung*. VS Verlag für Sozialwissenschaften GmbH.
- Ren, L., Wang, H., Li, J., Tang, Y., & Yang, C. (2025). AIGC for Industrial Time Series: From Deep-Generative Models to Large-Generative Models. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 1–18. <https://doi.org/10.1109/TSMC.2025.3598252>
- Ries, E. (2011). *The lean startup: How today's entrepreneurs use continuous innovation to create radically successful businesses* (1st ed). Crown Business.
- Ritchie, J., & Spencer, L. (2002). Qualitative Data Analysis for Applied Policy Research. In A. Huberman & M. Miles, *The Qualitative Researcher's Companion* (S. 305–329). SAGE Publications, Inc. <https://doi.org/10.4135/9781412986274.n12>

- Rogers, E. M. (2003). *Diffusion of innovations* (Fifth edition). Free Press.
- Röser, A. M., & Bartelt, C. (2024). A Generative AI and Neural Network Approach to Sustainable Digital Transformation: A Focus on Medical and Marketing Sectors. In C. Obádovics & Z. Széles (Hrsg.), *Fenntarthatósági átmenet: Kihívások és innovatív megoldások: Nemzetközi tudományos konferencia a Magyar Tudomány Ünnepe alkalmából* (S. 483–497). Soproni Egyetem Kiadó. <https://doi.org/10.35511/978-963-334-499-6-Roser-Bartelt>
- Runia, P., Wahl, F., & Geyer, O. (2019). *Marketing: Prozess- und Praxisorientierte Grundlagen* (5., aktualisierte und ergänzte Auflage). De Gruyter Oldenbourg.
- Sadiq, R. B., Safie, N., Abd Rahman, A. H., & Goudarzi, S. (2021). Artificial intelligence maturity model: A systematic literature review. *PeerJ Computer Science*, 7, e661. <https://doi.org/10.7717/peerj-cs.661>
- Schönberger, M. (2023). Artificial Intelligence for Small And Medium-Sized Enterprises: Identifying Key Applications and Challenges. *Journal of Business Management*, 21, 89–112. <https://doi.org/10.32025/JBM23004>
- Schwaewe, J., Peters, A., Kanbach, D. K., Kraus, S., & Jones, P. (2024). The new normal: The status quo of AI adoption in SMEs. *Journal of Small Business Management*, 1–35. <https://doi.org/10.1080/00472778.2024.2379999>
- Senge, P. M. (1990). *The fifth discipline: The art and practice of the learning organization* (1st ed). Doubleday/Currency.
- Sharma, A. (2024). *From Blueprint to Flight: Guiding Your First Generative AI Project - Revolutionizing Service Desk Operations*. In Review. <https://doi.org/10.21203/rs.3.rs-3944980/v1>
- Sklavos, G., Theodossiou, G., Papanikolaou, Z., Karelakis, C., & Ragazou, K. (2024). Environmental, Social, and Governance-Based Artificial Intelligence Governance: Digitalizing Firms' Leadership and Human Resources Management. *Sustainability*, 16(16), 7154. <https://doi.org/10.3390/su16167154>
- Sonntag, M., Mehmman, S., Mehmman, J., & Teuteberg, F. (2024). Development and Evaluation of a Maturity Model for AI Deployment Capability of Manufacturing Companies. *Information Systems Management*, 42(1), 37–67. <https://doi.org/10.1080/10580530.2024.2319041>
- Spencer, L. M., & Spencer, S. M. (1993). *Competence at work: Models for superior performance*. Wiley.

- Statistisches Bundesamt. (2024a). *53% in kleinen und mittleren Unternehmen tätig*. Kleine und mittlere Unternehmen. <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Unternehmen/Kleine-Unternehmen-Mittlere-Unternehmen/aktuell-beschaeftigte.html>
- Statistisches Bundesamt. (2024b). *Jedes fünfte Unternehmen nutzt künstliche Intelligenz*. (444). https://www.destatis.de/DE/Presse/Pressemitteilungen/2024/11/PD24_444_52911.html?templateQueryString=Jedes+fünfte+Unternehmen+nutzt+künstliche+Intelligenz
- Steinke, I. (1999). *Kriterien qualitativer Forschung: Ansätze zur Bewertung qualitativ-empirischer Sozialforschung*. Juventa.
- Sutton, R. I., & Staw, B. M. (1995). What Theory is Not. *Administrative Science Quarterly*, *40*(3), 371. <https://doi.org/10.2307/2393788>
- Szedlak, C., Leyendecker, B., Reinemann, H., & Kschischo, M. (2021). Risks and Benefits of Artificial Intelligence in Small-and-Medium Sized Enterprises. *Proceedings of the International Conference on Industrial Engineering and Operations Management Rome*, 11.
- Tawil, A.-R. H., Mohamed, M., Schmoor, X., Vlachos, K., & Haidar, D. (2024). Trends and Challenges towards Effective Data-Driven Decision Making in UK Small and Medium-Sized Enterprises: Case Studies and Lessons Learnt from the Analysis of 85 Small and Medium-Sized Enterprises. *Big Data and Cognitive Computing*, *8*(7), 79. <https://doi.org/10.3390/bdcc8070079>
- Teddlie, C., & Yu, F. (2007). Mixed Methods Sampling: A Typology With Examples. *Journal of Mixed Methods Research*, *1*(1), NP1–NP1. <https://doi.org/10.1177/2345678906292430>
- Teece, D. J., Pisano, G., & Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic Management Journal*, *18*(7), 509–533. [https://doi.org/10.1002/\(SICI\)1097-0266\(199708\)18:7%253C509::AID-SMJ882%253E3.0.CO;2-Z](https://doi.org/10.1002/(SICI)1097-0266(199708)18:7%253C509::AID-SMJ882%253E3.0.CO;2-Z)
- Tornatzky, L. G., & Fleischer, M. (1990). *The processes of technological innovation* (4. print). Lexington Books.
- Trist, E. L., & Bamforth, K. W. (1951). Some Social and Psychological Consequences of the Longwall Method of Coal-Getting: An Examination of the Psychological Situa-

- tion and Defences of a Work Group in Relation to the Social Structure and Technological Content of the Work System. *Human Relations*, 4(1), 3–38. <https://doi.org/10.1177/001872675100400101>
- Valencia, M. M. A. (2022). Principles, Scope, and Limitations of the Methodological Triangulation. *Investigacion y Educacion En Enfermeria*, 40(2). <https://doi.org/10.17533/udea.iee.v40n2e03>
- Van de Ven, A. H. (2007). *Engaged scholarship: A guide for organizational and social research*. Oxford University Press.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2023). *Attention Is All You Need* (arXiv:1706.03762). arXiv. <http://arxiv.org/abs/1706.03762>
- Waage, M., Weinbach, B. C., & Larsen, Ø. H. (2024). Digital and AI Maturity of Enterprises in Sogn Og Fjordane, a Rural Region of Norway. In R. Akerkar (Hrsg.), *AI, Data, and Digitalization* (Bd. 1810, S. 187–202). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-53770-7_13
- Wang, S., & Zhang, H. (2025). Promoting sustainable development goals through generative artificial intelligence in the digital supply chain: Insights from Chinese tourism SMEs. *Sustainable Development*, 33(1), 1231–1248. <https://doi.org/10.1002/sd.3152>
- Whetten, D. A. (1989). What Constitutes a Theoretical Contribution? *The Academy of Management Review*, 14(4), 490. <https://doi.org/10.2307/258554>
- Xu, M., Du, H., Niyato, D., Kang, J., Xiong, Z., Mao, S., Han, Z., Jamalipour, A., Kim, D. I., Shen, X., Leung, V. C. M., & Poor, H. V. (2024). Unleashing the Power of Edge-Cloud Generative AI in Mobile Networks: A Survey of AIGC Services. *IEEE Communications Surveys & Tutorials*, 26(2), 1127–1170. <https://doi.org/10.1109/COMST.2024.3353265>
- Xue, L., Shu, M., Awadalla, A., Wang, J., Yan, A., Purushwalkam, S., Zhou, H., Prabhu, V., Dai, Y., Ryoo, M. S., Kendre, S., Zhang, J., Tseng, S., Lujan-Moreno, G. A., Olson, M. L., Hinck, M., Cobbley, D., Lal, V., Qin, C., ... Xu, R. (2024). *xGen-MM (BLIP-3): A Family of Open Large Multimodal Models* (Version 3). arXiv. <https://doi.org/10.48550/ARXIV.2408.08872>
- Yin, R. K. (2014). *Case study research: Design and methods* (5. edition). SAGE.

- Zangemeister, C. (2014). *Nutzwertanalyse in der Systemtechnik: Eine Methodik zur multidimensionalen Bewertung und Auswahl von Projektalternativen* (5. Auflage 2014 (erweitert)). Zangemeister & Partner.
- Zhao, C., Song, Y., Wang, W., Feng, H., Ding, E., Sun, Y., Xiao, X., & Wang, J. (2024). *MonoFormer: One Transformer for Both Diffusion and Autoregression* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2409.16280>
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., Dong, Z., Du, Y., Yang, C., Chen, Y., Chen, Z., Jiang, J., Ren, R., Li, Y., Tang, X., Liu, Z., ... Wen, J.-R. (2025). *A Survey of Large Language Models* (arXiv:2303.18223). arXiv. <https://doi.org/10.48550/arXiv.2303.18223>
- Zhou, H., Hu, C., Yuan, D., Yuan, Y., Wu, D., Liu, X., Han, Z., & Zhang, C. (2024). *Generative AI as a Service in 6G Edge-Cloud: Generation Task Offloading by In-context Learning* (Version 3). arXiv. <https://doi.org/10.48550/ARXIV.2408.02549>

Halbstrukturierter Interviewleitfaden

Implementierung generativer KI innerhalb der Marketingprozesse mittelständischer Unternehmen

Interne Perspektive

Einleitung

- Begrüßung und Vorstellung des Interviewziels.
- Erläuterung des Datenschutzes und Einholung der Zustimmung zur Aufzeichnung.
- Einführung in das Thema:
 - „Die Studie untersucht den Implementierungsprozess von generativer KI innerhalb der Marketingprozesse mittelständischer Unternehmen.“
- Abfrage noch offener Punkte im Zuge der **Expertenbewertung**:
 - *Wie würdest du deine eigene Projekterfahrung bei der Implementierung generativer KI einschätzen? Bitte verwende dabei eine Skala von 1 bis 6, wobei 1 für ‚keine Erfahrung‘ und 6 für ‚ausgeprägte Erfahrung‘ steht.*
 - *Welche Projektrolle hast du eingenommen?*

Hauptteil

Priorität 1

Themenblock 1 – Verlauf Implementierungsprozesses

1. Wie verlief der Implementierungsprozess von der Idee bis zur Umsetzung?
2. Welche internen Stakeholder und externe Akteure waren an den einzelnen Phasen beteiligt und welche Kompetenzen brachten diese mit?
3. Welche Prozessschritte waren für die Implementierung besonders entscheidend?
 - a. *Nachfrage: Nach welcher Reihenfolge wurden die Prozessschritte in der Regeldurchgeführt?*

Themenblock 2 – Abgeleitete Implementierungsstrategie (KI-Strategie)

1. Wie seid ihr bei der Entwicklung der Implementierungsstrategie vorgegangen? Gab es bestimmte Modelle oder Ansätze, die ihr verwendet habt?
 - a. Gab es auch Ansätze, die ihr verworfen habt? Wenn ja, warum?
2. Wie habt ihr entschieden, welche spezifischen Anwendungsfälle oder Bereiche im Marketing priorisiert werden?
 - a. Nach welchen Kriterien wurden die Anwendungsfälle priorisiert?

Themenblock 3 – Anwendung von Basistechnologien (KI-Technologien)

1. Welche Technologien oder Plattformen wurden während der Implementierung eingesetzt?
 - a. *Nachfrage: Welche Kriterien waren für die Auswahl entscheidend?*
2. Wie wurden die eingesetzten Technologien in bestehende Systeme und Prozesse integriert?
 - a. *Nachfrage: Gab es technische Herausforderungen bei der Integration, und wie wurden diese gelöst?*

Priorität 2

Themenblock 4 – Ableitung von Bewertungskriterien zur Erfolgsmessung

1. Welche spezifischen KPI oder Benchmarks haben sich als nützlich erwiesen, um den Erfolg der Implementierung im zu bewerten?
 - a. *Nachfrage:* Gab es Rückmeldungen aus dem Team oder von Kunden, die Erfolg oder Misserfolg sichtbar gemacht haben?

Themenblock 5 – Zukünftige Projektvorhaben (KI-Roadmap)

1. Welche zukünftigen Schritte plant ihr, um den Einsatz generativer KI im Marketing weiterzuentwickeln?

Abschluss

- Zusammenfassung der Hauptpunkte.
- Möglichkeit für zusätzliche Anmerkungen der Teilnehmenden: „*Gibt es etwas, das wir nicht angesprochen haben, das Du für wichtig halten?*“
- Dank für die Teilnahme und Erläuterung der nächsten Schritte.

Halbstrukturierter Interviewleitfaden

Implementierung generativer KI innerhalb der Marketingprozesse mittelständischer Unternehmen

Externe Perspektive

Einleitung

- Begrüßung und Vorstellung des Interviewziels.
- Erläuterung des Datenschutzes und Einholung der Zustimmung zur Aufzeichnung.
- Einführung in das Thema:
 - „Die Studie untersucht den Implementierungsprozess von generativer KI innerhalb der Marketingprozesse mittelständischer Unternehmen.“
- Abfrage noch offener Punkte im Zuge der **Expertenbewertung**:
 - *Wie würdest du deine eigene Projekterfahrung bei der Implementierung generativer KI einschätzen? Bitte verwende dabei eine Skala von 1 bis 6, wobei 1 für ‚keine Erfahrung‘ und 6 für ‚ausgeprägte Erfahrung‘ steht.*
 - *Welche Projektrolle hast du eingenommen?*

Hauptteil

Priorität 1

Themenblock 1: Verlauf des Implementierungsprozesses

1. Wie verlief der Implementierungsprozess in den von dir begleiteten Unternehmen von der Idee bis zur Umsetzung?
2. Welche Stakeholder im Unternehmen hast du in den einzelnen Phasen herangezogen, und welche Kompetenzen waren dabei entscheidend?
3. Welche Prozessschritte waren für die Implementierung besonders entscheidend?
 - a. *Nachfrage: Nach welcher Reihenfolge wurden die Prozessschritte in der Regeldurchgeführt?*

Themenblock 2: Abgeleitete Implementierungsstrategie (KI-Strategie)

1. Wie gehen von dir begleitete Unternehmen bei der Entwicklung der Implementierungsstrategie vor? Gab es bestimmte Modelle oder Ansätze, die verwendet wurden?
 - a. Gab es auch Ansätze, die verworfen wurden? Wenn ja, warum?
2. Wie unterscheiden sich die Strategien je nach Unternehmensgröße oder Branche?

Themenblock 3: Anwendung von Basistechnologien (KI-Technologien)

1. Welche Technologien oder Plattformen wurden während der Implementierung eingesetzt?
 - a. *Nachfrage: Welche Kriterien waren für die Auswahl entscheidend?*
2. Wie wurden die eingesetzten Technologien in bestehende Systeme und Prozesse integriert?
 - a. *Nachfrage: Gab es technische Herausforderungen bei der Integration, und wie wurden diese gelöst?*

Priorität 2

Themenblock 4: Ableitung von Bewertungskriterien zur Erfolgsmessung

1. Welche spezifischen KPI oder Benchmarks haben sich als nützlich erwiesen, um den Erfolg der Implementierung im zu bewerten?
 - a. Nachfrage: Welche Ergebnisse beobachtest du bei Unternehmen typischerweise nach der Implementierung?

Themenblock 5: Zukünftige Projektvorhaben (KI-Roadmap)

1. Welche Schritte sollten Unternehmen zukünftig gehen, um den Einsatz generativer KI im Marketing weiterzuentwickeln?

Abschluss

- Zusammenfassung der Hauptpunkte.
- Möglichkeit für zusätzliche Anmerkungen der Teilnehmenden: „*Gibt es etwas, das wir nicht angesprochen haben, das Du für wichtig halten?*“
- Dank für die Teilnahme und Erläuterung der nächsten Schritte.

Halbstrukturierter Interviewleitfaden

Implementierung generativer KI im Unternehmenskontext

Interne Perspektive

Zweck und Zielsetzung

- Zentrale Aspekte der KI-Implementierung empirisch erfassen (Prozessschritte, Strategien, Basistechnologien, Bewertungskriterien, KI-Roadmaps) als Basis für ein konzeptuelles Implementierungsframework.
- Durch halbstrukturierte Interviews vergleichbare, zugleich kontextreiche Erfahrungsberichte gewinnen, um Muster und Entscheidungslogiken im Mittelstand sichtbar zu machen.
- Datengrundlage für die induktive Kategorienbildung (qualitative Inhaltsanalyse) schaffen und mit Dokumentenbefunden triangulieren, um den Erstentwurf des Frameworks zu fundieren.
- Praxisnahe Handlungsmuster und Wenn–Dann-Entscheidungsregeln für KMU ableiten und die Grundlage für die anschließende Validierung (Member Checking) legen.

Einleitung

- Begrüßung und Vorstellung des Themas sowie des Interviewziels.
- Erläuterung der Interviewstruktur.
- Erläuterung des Datenschutzes und Einholung der Zustimmung zur Aufzeichnung, Weiterverarbeitung und Analyse.
- Abfrage noch offener Punkte im Zuge der **Expertenbewertung**:
 - *Wie würdest du deine eigene Projekterfahrung bei der Implementierung generativer KI einschätzen? (Skala von 1 bis 6, 1 ‚keine Erfahrung‘, 6 ‚ausgeprägte Erfahrung‘).*
 - *Welche Projektrolle hast du eingenommen?*

Hauptteil

Priorität 1

Themenblock 1 – Verlauf Implementierungsprozesses

1. Wie verlief der Implementierungsprozess von der Idee bis zur Umsetzung?
 - a. *In welcher Reihenfolge verliefen die Prozessschritte zur Implementierung?*
 - b. *Wie genau gestaltet sich der Prozessschritt [Prozessschritt X]?*
 - c. *Gab es Phasen oder Aspekte im Prozess, die weniger erfolgreich verliefen? Woran lag das?*
2. Welche Prozessschritte sind für die Implementierung besonders entscheidend?
 - a. *Wurden Prozessschritte im Laufe der Implementierung übersprungen? Wenn ja: Welche Beweggründe lagen hierfür vor?*
3. Welche internen Stakeholder und externe Akteure waren an den einzelnen Phasen beteiligt
 - a. *Welche Kompetenzen brachten die Stakeholder mit?*

Themenblock 2 – Abgeleitete Implementierungsstrategie (KI-Strategie)

1. Wie sieht die Strategie deines Unternehmens zur Integration von generativer KI aus? Kannst du erfolgreiche Umsetzungsbeispiele nennen?

2. Wie seid ihr bei der Entwicklung der Implementierungsstrategie vorgegangen?
 - b. *Gab es bestimmte Modelle oder Ansätze, die ihr verwendet habt?*
 - c. *Wie hilfreich waren die verwendeten Modelle oder Ansätze in der Praxis?*
 - d. *Gab es auch Ansätze, die ihr verworfen habt?*
Wenn ja: Welche Beweggründe lagen hierfür vor?
3. Wie habt ihr entschieden, welche spezifischen Anwendungsfälle oder Bereiche priorisiert werden?
 - e. *Nach welchen Kriterien wurden die Anwendungsfälle priorisiert?*

Themenblock 3 – Anwendung von Basistechnologien (KI-Technologien)

1. Welche Technologien oder Plattformen wurden während der Implementierung eingesetzt?
 - a. *Welche Kriterien waren für die Auswahl entscheidend?*
2. Wie wurden die eingesetzten Technologien in bestehende Systeme und Prozesse integriert?
 - a. *Gab es technische Herausforderungen bei der Integration, und wie wurden diese gelöst?*

Priorität 2

Themenblock 4 – Ableitung von Bewertungskriterien zur Erfolgsmessung

1. Welche spezifischen KPI haben sich als nützlich erwiesen, um den Erfolg der Implementierung im zu bewerten?
 - a. *Welche Schlüsse wurden bislang aus der Betrachtung von [KPI X] gezogen?*
 - b. *Welche Erfolge oder Misserfolge konnten bereits identifiziert werden?*

Themenblock 5 – Zukünftige Projektvorhaben (KI-Roadmap)

2. Welche zukünftigen Schritte plant ihr, um den Einsatz generativer KI voranzutreiben?
 - a. *Welche Trendthemen siehst du aktuell im Bereich Künstliche Intelligenz, die Fachbereiche wie das Marketing langfristig beeinflussen werden?*

Abschluss

- Zusammenfassung der Hauptpunkte des Interviews.
- Zusätzliche Anmerkungen der Teilnehmenden: „Gibt es etwas, das wir nicht angesprochen haben, das Du für wichtig halten?“
- Dank für die Teilnahme und Erläuterung der nächsten Schritte.

Halbstrukturierter Interviewleitfaden

Implementierung generativer KI im Unternehmenskontext

Externe Perspektive

Zweck und Zielsetzung

- Zentrale Aspekte der KI-Implementierung empirisch erfassen (Prozessschritte, Strategien, Basistechnologien, Bewertungskriterien, KI-Roadmaps) als Basis für ein konzeptuelles Implementierungsframework.
- Durch halbstrukturierte Interviews vergleichbare, zugleich kontextreiche Erfahrungsberichte gewinnen, um Muster und Entscheidungslogiken im Mittelstand sichtbar zu machen.
- Datengrundlage für die induktive Kategorienbildung (qualitative Inhaltsanalyse) schaffen und mit Dokumentenbefunden triangulieren, um den Erstentwurf des Frameworks zu fundieren.
- Praxisnahe Handlungsmuster und Wenn–Dann-Entscheidungsregeln für KMU ableiten und die Grundlage für die anschließende Validierung (Member Checking) legen.

Einleitung

- Begrüßung und Vorstellung des Themas sowie des Interviewziels.
- Erläuterung der Interviewstruktur.
- Erläuterung des Datenschutzes und Einholung der Zustimmung zur Aufzeichnung, Weiterverarbeitung und Analyse.
- Abfrage noch offener Punkte im Zuge der **Expertenbewertung**:
 - *Wie würdest du deine eigene Projekterfahrung bei der Implementierung generativer KI einschätzen? (Skala von 1 bis 6, 1 ‚keine Erfahrung‘, 6 ‚ausgeprägte Erfahrung‘).*
 - *Welche Projektrolle hast du eingenommen?*

Hauptteil

Priorität 1

Themenblock 1: Verlauf des Implementierungsprozesses

1. Wie verlief der Implementierungsprozess in den von dir begleiteten Unternehmen von der Idee bis zur Umsetzung?
 - a. *In welcher Reihenfolge verliefen die Prozessschritte zur Implementierung?*
 - b. *Wie genau gestaltet sich der Prozessschritt [Prozessschritt X]?*
 - c. *Gab es Phasen oder Aspekte im Prozess, die weniger erfolgreich verliefen? Woran lag das?*
2. Welche Prozessschritte waren für die Implementierung besonders entscheidend?
 - a. *Wurden Prozessschritte im Laufe der Implementierung übersprungen? Wenn ja: Welche Beweggründe lagen hierfür vor?*
3. Welche internen Stakeholder und externe Akteure waren an den einzelnen Phasen beteiligt
 - b. *Welche Kompetenzen brachten die Stakeholder mit?*

Themenblock 2: Abgeleitete Implementierungsstrategie (KI-Strategie)

1. Kannst du Beispiele nennen, in denen generative KI erfolgreich integriert wurde? Welche Strategie stand dabei im Vordergrund?
2. Wie gehen von dir begleitete Unternehmen bei der Entwicklung der Implementierungsstrategie vor?
 - a. *Gab es bestimmte Modelle oder Ansätze, die verwendet wurden?*
 - b. *Wie hilfreich waren die verwendeten Modelle oder Ansätze in der Praxis?*
 - c. *Gab es auch Ansätze, die verworfen wurden? Wenn ja, warum?*
3. Wie priorisieren die Unternehmen bestimmte Anwendungsfälle von generativer KI?
 - a. *Nach welchen Kriterien erfolgt die Priorisierung der Anwendungsfälle?*

Themenblock 3: Anwendung von Basistechnologien (KI-Technologien)

1. Welche Technologien oder Plattformen wurden während der Implementierung eingesetzt?
 - a. Welche Kriterien waren für die Auswahl entscheidend?
2. Wie wurden die eingesetzten Technologien in bestehende Systeme und Prozesse integriert?
 - a. *Gab es technische Herausforderungen bei der Integration, und wie wurden diese gelöst?*

Priorität 2

Themenblock 4: Ableitung von Bewertungskriterien zur Erfolgsmessung

1. Welche spezifischen KPI haben sich als nützlich erwiesen, um den Erfolg der Implementierung im zu bewerten?
 - a. *Welche Schlüsse wurden bislang aus der Betrachtung von [KPI X] gezogen?*
 - b. *Welche Erfolge oder Misserfolge konnten bereits identifiziert werden?*

Themenblock 5: Zukünftige Projektvorhaben (KI-Roadmap)

1. Welche Schritte sollten Unternehmen zukünftig gehen, um den Einsatz generativer KI voranzutreiben?
 - a. *Nachfrage: Welche Trendthemen siehst du aktuell im Bereich Künstliche Intelligenz, die Fachbereiche wie das Marketing langfristig beeinflussen werden?*

Abschluss

- Zusammenfassung der Hauptpunkte des Interviews.
- Zusätzliche Anmerkungen der Teilnehmenden: „Gibt es etwas, das wir nicht angesprochen haben, das Du für wichtig halten?“
- Dank für die Teilnahme und Erläuterung der nächsten Schritte.

Anhang E: Interviewprotokolle Expert*inneninterviews

Hinweis: Die vollständigen Protokolle der im Rahmen dieser Forschungsarbeit geführten Expert*inneninterviews sowie der Validierungsgespräche werden aus Gründen des Umfangs nicht im Anhang abgedruckt. Sie sind dem beiliegenden Datenträger zu entnehmen.

Anhang F: MAXQDA

Hinweis: Das im Zuge der qualitativen Inhaltsanalyse sowie der Dokumentenanalyse entwickelte, vollständige Kategoriensystem sowie weitere Unterlagen werden aus Gründen des Umfangs nicht im Anhang abgedruckt. Sie sind dem beiliegenden Datenträger zu entnehmen.

Halbstrukturierter Interviewleitfaden

Implementierung generativer KI im Unternehmenskontext

Validierungsgespräche

Zweck und Zielsetzung

- Validierung der Gesamtlogik und Praxistauglichkeit des Implementierungsframeworks.
- Fokussierte Konsensbildung zu identifizierten Dissenspunkten (STRAT, TECH, EVAL, FUT).
- Ableitung kontextsensitiver Entscheidungsregeln und Minimalanforderungen.

Einleitung

- Ziel des Gesprächs ist die Validierung der Gesamtstruktur des Frameworks und die gemeinsame Schärfung zentraler Dissenspunkte.
- Gearbeitet wird mit offenen Fragen.
- Fokus liegt auf Entscheidungslogiken und Kontextbedingungen.
- Ableitung klarer Minimalanforderungen und kontextsensitiver Entscheidungsregeln ab je Block am Ende.

Hauptteil

Gesamtvalidierung des Implementierungsframeworks

1. Inwiefern ist die Gesamtstruktur des Frameworks (Ziel, Aufbau, Prozesslogik) plausibel und anschlussfähig?
 - a. Welche Lücken, Redundanzen oder erklärungsbedürftige Übergänge könnten die Anwendung behindern?
 - b. Welche konkreten Anpassungen würden die Nutzbarkeit am stärksten erhöhen und warum?

MODERATIONSNOTIZ: ZIEL IST EINE PRÄZISE BENENNUNG VON 2–3 PRIORISIERTEN ANPASSUNGSPUNKTEN (MIT KURZER BEGRÜNDUNG), DIE DIREKT IN DIE FRAMEWORK-REVISION ÜBERFÜHRT WERDEN KÖNNEN.

Dissenspunkte

STRAT – Implementierungsstrategie und Steuerungslogiken

2. Wie lässt sich in KMU die Balance zwischen zentraler Steuerung (Ressourcen, Governance durch Management) und dezentraler Initiative (Use-Case-Nähe durch Fachabteilung) so gestalten, dass Skalierbarkeit und Akzeptanz gleichermaßen gesichert werden, ohne die Umsetzungsgeschwindigkeit zu drosseln?
 - a. Welche konkreten Bedingungen (z. B. regulatorisches Risiko, Budgethöhe, Datenklassen, Sicherheitsanforderungen) sprechen eindeutig für zentrale Steuerung und welche für dezentrale Initiative?
 - b. Welche minimalen Governance-Elemente (z. B. Policy, Freigabeprozess, Verantwortlichkeiten) sind unverzichtbar, und in welchen Situationen reicht eine bewusst „leichte“ Formalisierung?

MODERATIONSNOTIZ: EXTRAHIEREN SIE 1–2 WENN–DANN-REGELN (Z. B. „WENN SENSIBLE DATENKLASSEN X, DANN ZENTRALE STEUERUNG Y“) UND 1 MINIMALANFORDERUNG (Z. B. „LEAN GOVERNANCE“ MIT PFLICHT-POLICY UND VERANTWORTLICHKEIT).

TECH – Technologieauswahl und Integrationsgrad

3. Nach welchen Kriterien wird zwischen ganzheitlichen KI-Lösungen und spezialisierten KI-Lösungen sowie zwischen Cloud- und Self-Hosting/Edge-Optionen entschieden?
 - a. Wie gewichtest Du Datenschutz/Compliance, Lock-in-Risiko, vorhandene IT-Kapazität, Latenz/Verfügbarkeit und Time-to-Value in diesen Entscheidungen?
 - b. In welchen Fällen ist eine leichte Integration (z. B. Frontend-Plugins, limitierte API-Anbindung) ausreichend und wann erfordert der Nutzen zwingend eine tiefgehende Integration (APIs, Datenpipelines, Identity/Access), inklusive organisatorischer Flankierung (Prozessanpassungen, Schulungen, Kommunikation)?

MODERATIONSNOTIZ: ZIELEN SIE AUF 1–2 WENN–DANN-REGELN (Z. B. „WENN HOHE DATENSCHUTZANFORDERUNG UND GERINGE IT-KAPAZITÄT, DANN ...“) UND BENENNEN SIE EINE MINIMALANFORDERUNG (Z. B. ZENTRALER IDENTITÄTS- UND ZUGRIFFSMECHANISMUS).

EVAL – Erfolgsmessung und Bewertungskriterien

4. Wie sollte Erfolgsmessung gestaltet sein, damit neben kurzfristigen Effizienzgewinnen auch qualitative Wirkungen (z. B. Akzeptanz, Arbeitsqualität, Lernfortschritt) belastbar erfasst und für Entscheidungen nutzbar gemacht werden?
 - a. Welche Kernkriterien sollten in jedem Use Case erhoben werden, und welche Kriterien variieren kontextspezifisch?
 - b. An welchen Zeitpunkten ist eine formative Evaluation besonders wirksam (z. B. vor Rollout, während Pilot, nach 4–6 Wochen Nutzung), und wie wird das Feedback konkret in Kurskorrekturen überführt?

MODERATIONSNOTIZ: FÜHREN SIE ZU 1–2 WENN–DANN-REGELN (Z. B. „WENN HOHER VERÄNDERUNGSGRAD, DANN FORMATIVE EVALUATION VOR UND NACH PILOT“) UND EINER MINIMALANFORDERUNG (Z. B. PFLICHT-KERNSET AUS TECHNISCHER, NUTZERBEZOGENER UND PROZESSUALER KENNZAHLE).

FUT – KI-Roadmap und Zukunftsausrichtung

5. Wie sollte eine KI-Roadmap aufgebaut sein, damit sie technologische Dynamik abbildet und zugleich kulturelle Anschlussfähigkeit fördert, ohne in starre Planungsgliedern zu verfallen?
 - a. Welche Signale (z. B. Technologiereife, Kultur-/Change-Bereitschaft, Teamkompetenzen, Risikolage) sprechen für adaptive Pfade gegenüber linearen Meilensteinen, und wie priorisierst Du diese Signale?
 - b. Wie wird das Verhältnis von Automatisierung und menschlicher Supervision geregelt (Verantwortlichkeiten, Qualitätssicherung), und welche Rollen-/Kompetenzanpassungen sind dafür minimal notwendig?

MODERATIONSNOTIZ: VERDICHTEN SIE 1–2 WENN–DANN-REGELN (Z. B. „WENN HOHE TECHNODYNAMIK UND NIEDRIGE KULTURREIFE, DANN ...“) UND EINE MINIMALANFORDERUNG (Z. B. DEFINIERTE VERANTWORTLICHKEIT FÜR SUPERVISION UND KLARE ESKALATIONSPFADE).

Abschluss

6. Welche eine Änderung am Framework hätten aus Deiner Sicht die größte Hebelwirkung?

Halbstrukturierter Interviewleitfaden

Implementierung generativer KI im Unternehmenskontext

Validierungsgespräche

Zweck und Zielsetzung

- Validierung der Gesamtlogik und Praxistauglichkeit des Implementierungsframeworks.
- Fokussierte Konsensbildung zu identifizierten Dissenspunkten (STRAT, TECH, EVAL, FUT).
- Ableitung kontextsensitiver Entscheidungsregeln und Minimalanforderungen.

Einleitung

- Ziel des Gesprächs ist die Validierung der Gesamtstruktur des Frameworks und die gemeinsame Schärfung zentraler Dissenspunkte.
- Gearbeitet wird mit offenen Fragen.
- Fokus liegt auf Entscheidungslogiken und Kontextbedingungen.
- Ableitung klarer Minimalanforderungen und kontextsensitiver Entscheidungsregeln ab je Block am Ende.

Hauptteil

Gesamtvalidierung des Implementierungsframeworks

1. Inwiefern ist die Gesamtstruktur des Frameworks plausibel und realisierbar?
 - a. Welche Lücken, Redundanzen oder erklärungsbedürftige Übergänge sind aufgefallen?
 - b. Welche konkreten Anpassungen würden die Nutzbarkeit am stärksten erhöhen und warum?

MODERATIONSNOTIZ: ZIEL IST EINE PRÄZISE BENENNUNG VON 2–3 PRIORISIERTEN ANPASSUNGSPUNKTEN (MIT KURZER BEGRÜNDUNG), DIE DIREKT IN DIE FRAMEWORK-REVISION ÜBERFÜHRT WERDEN KÖNNEN.

Dissenspunkte

STRAT – Implementierungsstrategie und Steuerungslogiken

2. Wie sollten Leitplanken des Management/Vorstands ausgestaltet werden, um KI-Initiativen aus Fachabteilung nicht negativ zu torpedieren?

MODERATIONSNOTIZ: HINWEIS AUF DISSENS ZWISCHEN TOP-DOWN UND BOTTOM-UP. VERWEIS AUF BISHERIGE GESPRÄCHE IN DENEN POSTULIERT WIRD, DAS LEITPLANKEN TOP-DOWN GESETZT WERDEN MÜSSEN, DIE BOTTOM-UP KI-INITIATIVEN NICHT NEGATIV BEEINFLUSSEN.

TECH – Technologieauswahl und Integrationsgrad

3. Wie sollte entschieden werden, ob ein hybrider Hosting-Ansatz oder reiner Cloud- bzw. Server-Ansatz realisiert werden sollte?

MODERATIONSNOTIZ: HINWEIS AUF DISSENS ZWISCHEN CLOUD UND SERVER HOSTING. VERWEIS AUF BISHERIGE GESPRÄCHE IN DENEN POSTULIERT WIRD, DAS EIN HYBRIDER ANSATZ ALS EFFIZIENTESTE LÖSUNG ANGESEHEN WIRD.

EVAL – Erfolgsmessung und Bewertungskriterien

4. Wie sollte Erfolgsmessung gestaltet sein, damit neben kurzfristigen Effizienzgewinnen auch qualitative Wirkungen (z. B. Akzeptanz) belastbar erfasst und für Entscheidungen nutzbar gemacht werden?

MODERATIONSNOTIZ: FÜHREN SIE ZU 1–2 WENN–DANN-REGELN (Z. B. „WENN HOHER VERÄNDERUNGSGRAD, DANN FORMATIVE EVALUATION VOR UND NACH PILOT“) UND EINER MINIMALANFORDERUNG (Z. B. PFLICHT-KERNSET AUS TECHNISCHER, NUTZERBEZOGENER UND PROZESSUALER KENNZAHL).

FUT – KI-Roadmap und Zukunftsausrichtung

5. Wie sollte eine KI-Roadmap aufgebaut sein, damit kulturelle Anschlussfähigkeit fördert, ohne in starre Planungslogiken zu verfallen?

MODERATIONSNOTIZ: VERDICHTEN SIE 1–2 WENN–DANN-REGELN (Z. B. „WENN HOHE TECHNODYNAMIK UND NIEDRIGE KULTURREIFE, DANN ...“) UND EINE MINIMALANFORDERUNG (Z. B. DEFINIERTE VERANTWORTLICHKEIT FÜR SUPERVISION UND KLARE ESKALATIONSPFADE).

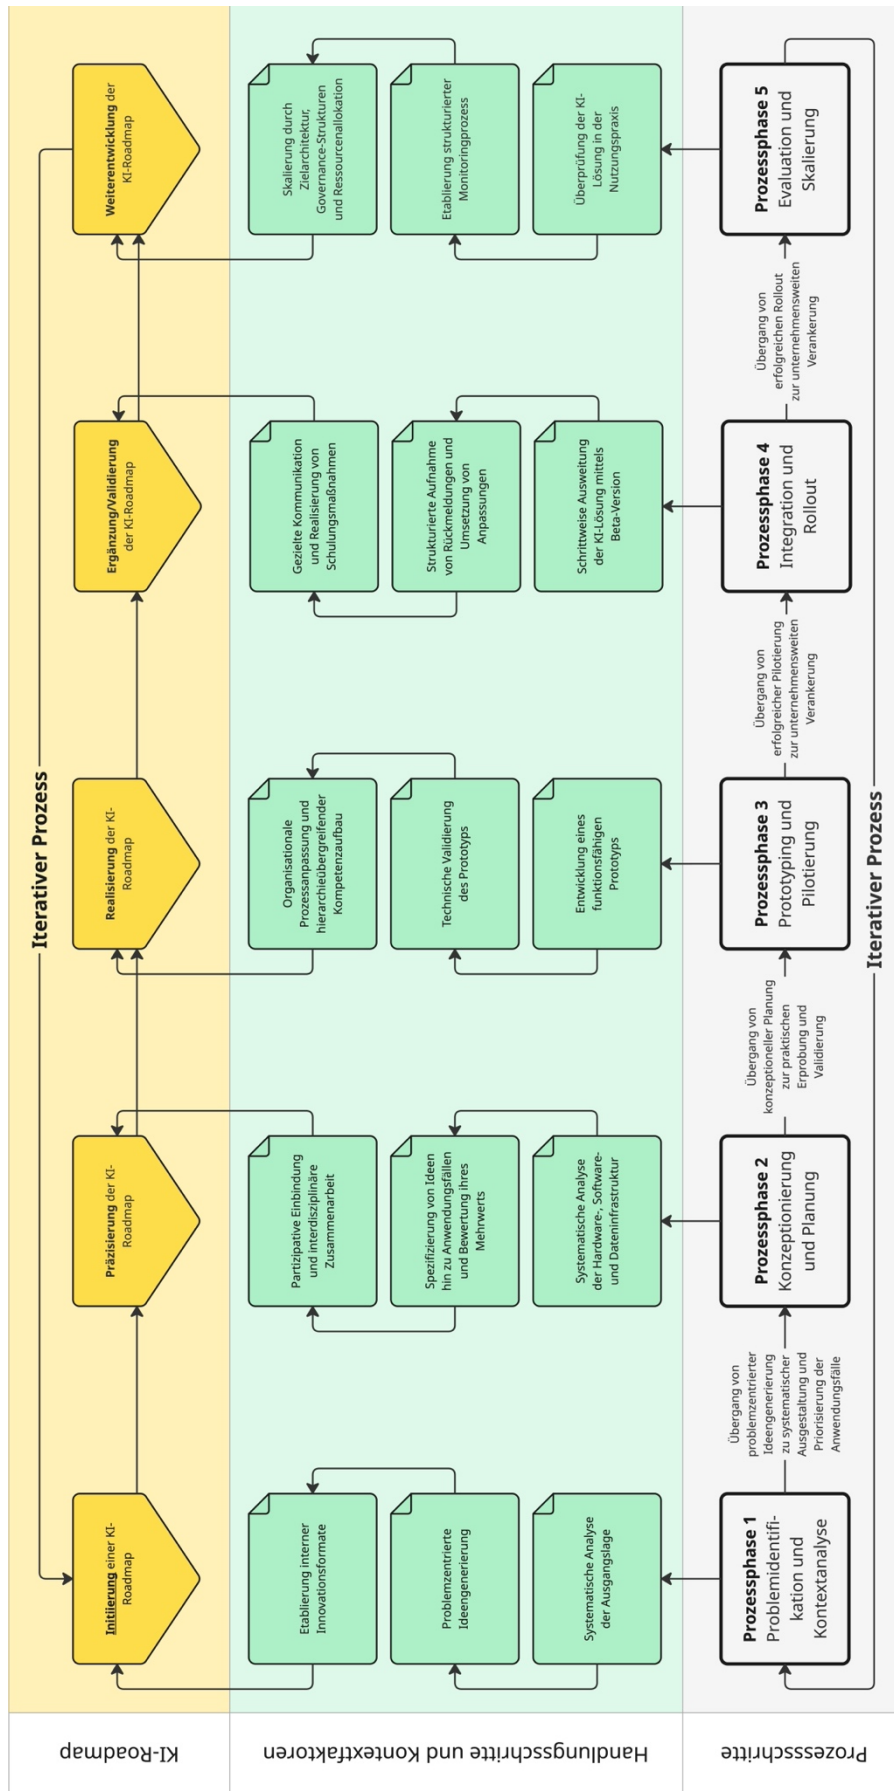
Abschluss

6. Welche Aspekte wurde im Validierungsgespräch nicht angesprochen, die an dieser Stelle ergänzend zur Sprache kommen sollten?

Anhang I: Transkripte der Expert*inneninterviews, Podcastfolgen und Validierungsgespräche

Hinweis: Die vollständigen Transkripte der Expert*inneninterviews, der Podcastfolgen sowie der Validierungsgespräche werden aus Gründen des Umfangs nicht im Anhang dieser Forschungsarbeit abgedruckt. Sie sind dem beiliegenden Datenträger zu entnehmen.

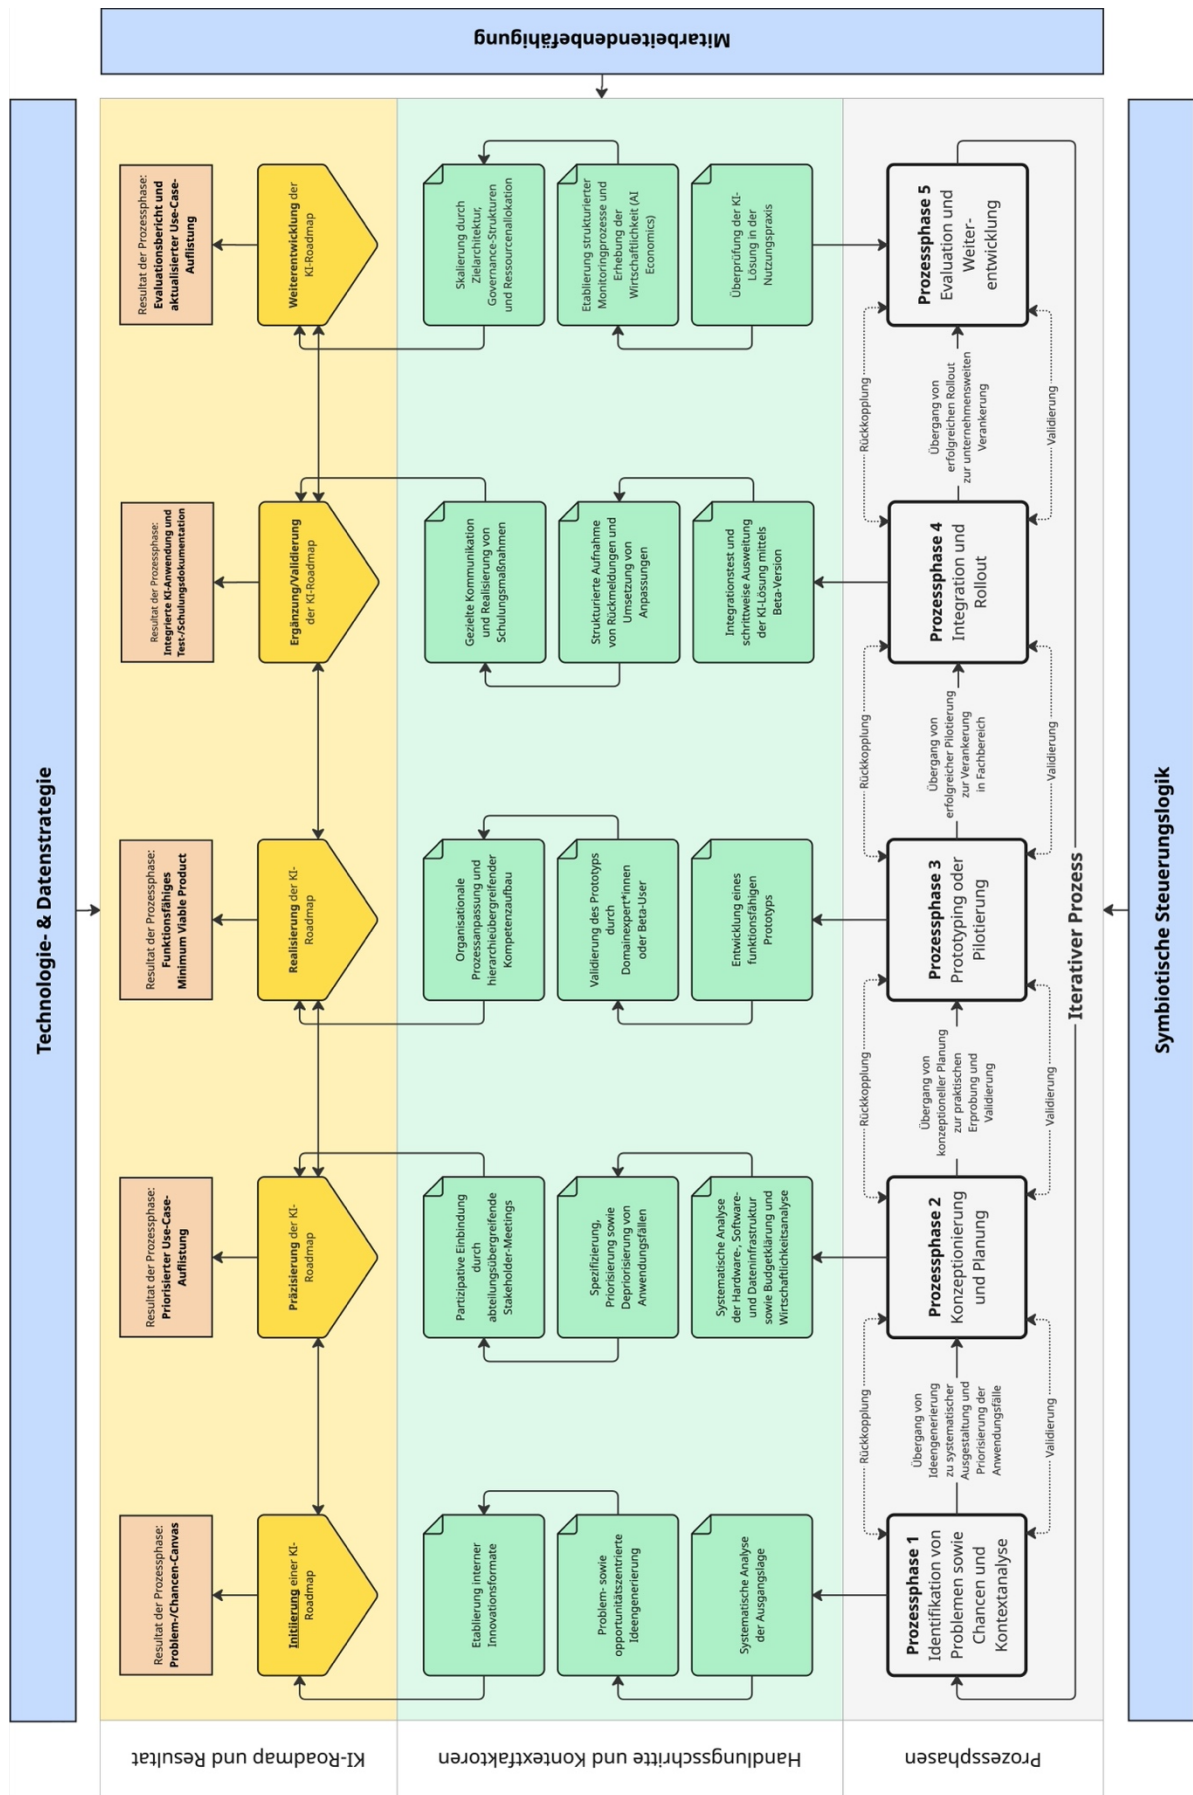
Anhang J: Erstentwurf Implementierungsframework



Anhang K: Datenmatrix Framework Analysis

Hinweis: Die im Zuge der Framework Analysis entwickelte Datenmatrix wird aus Gründen des Umfangs nicht im Anhang abgedruckt. Sie ist dem beiliegenden Datenträger zu entnehmen.

Anhang L: Finalversion Implementierungsframework



Anhang M: Glossar

Begriffe aus Kapitel 2.2.1

- **Attention-Mechanismen:** Neuronale Netzwerkarchitekturen, die es einem Modell ermöglichen, bei der Verarbeitung von Eingabedaten (z. B. einem Satz) bestimmte Teile als relevanter einzustufen und diesen eine höhere "Aufmerksamkeit" zu widmen. Dies verbessert die kontextuelle Erfassung und die Qualität der Modellergebnisse (Glauner, 2024; Vaswani et al., 2023).
- **Rekurrente sowie konvolutionale Modelle:**
 - **Rekurrente Neuronale Netze (RNNs):** Modelle, die für die Verarbeitung sequenzieller Daten (z. B. Zeitreihen, Text) konzipiert sind. Sie besitzen eine Art "Gedächtnis", das es ihnen erlaubt, Informationen aus vorherigen Schritten in die aktuelle Verarbeitung einzubeziehen (Glauner, 2024).
 - **Konvolutionale Neuronale Netze (CNNs):** Modelle, die primär in der Bildverarbeitung eingesetzt werden. Sie verwenden Faltungsoperationen (Convolutions), um hierarchische Muster und Merkmale in den Daten (z. B. Kanten, Formen) zu erkennen (Glauner, 2024).

Begriffe aus Kapitel 2.2.2

- **Datenaugmentation:** Techniken zur künstlichen Vergrößerung eines Datensatzes. Dabei werden aus den vorhandenen Daten neue, leicht modifizierte Datenpunkte generiert (z. B. durch Drehen eines Bildes oder Paraphrasieren eines Satzes), um die Robustheit und Generalisierungsfähigkeit des Modells zu verbessern (Glauner, 2024; Z. Li et al., 2024).
- **Datenkompression:** Verfahren zur Reduzierung des Speicherbedarfs von Daten. Ziel ist es, die Datenmenge zu verringern, um Speicherplatz zu sparen und die Übertragungsgeschwindigkeit zu erhöhen, während der Informationsgehalt weitestgehend erhalten bleibt (Pan et al., 2024).
- **Denoising-Prozedur:** Ein Verfahren, das darauf abzielt, "Rauschen" oder irrelevante Informationen aus einem Datensatz zu entfernen. Im Kontext von generativen Modellen (wie Diffusionsmodellen) ist dies der schrittweise Prozess, aus einem verrauschten Signal ein klares und kohärentes Datum (z. B. ein Bild) zu rekonstruieren (Z. Li et al., 2024).

- **Feature Learning (Merkmalslernen):** Ein Bereich des maschinellen Lernens, bei dem ein Modell selbstständig lernt, relevante Merkmale oder Repräsentationen aus Rohdaten zu extrahieren. Anstatt dass Merkmale manuell definiert werden müssen, identifiziert das Modell die für eine Aufgabe nützlichsten Muster autonom (Feuerriegel et al., 2023; Glauner, 2024).
- **Few-Shot-Learning:** Ein Ansatz des maschinellen Lernens, bei dem ein Modell darauf trainiert wird, eine Aufgabe mit nur sehr wenigen Beispielen (Shots) zu erlernen. Dies steht im Gegensatz zum traditionellen Training, das oft Tausende von Beispielen erfordert (Chern et al., 2024; Xue et al., 2024).
- **In-Context-Learning:** Die Fähigkeit großer Sprachmodelle, eine neue Aufgabe zur Laufzeit (Inferenz) zu erlernen, indem relevante Informationen und Beispiele direkt im Eingabeprompt bereitgestellt werden, ohne dass eine Neugewichtung des Modells erforderlich ist (Chern et al., 2024; Xue et al., 2024; Zhou et al., 2024).

Begriffe aus Kapitel 2.3.3

- **Cloud-basierte Modellendpunkte:** Schnittstellen (APIs), die auf einer Cloud-Infrastruktur gehostet werden und den Zugriff auf ein trainiertes Machine-Learning-Modell ermöglichen. Nutzer können Daten an diesen Endpunkt senden und erhalten eine Vorhersage des Modells zurück (Gan et al., 2023; Paaß & Giesselbach, 2023).
- **Edge-Inference-Systeme:** Systeme, bei denen die Inferenz (die Anwendungsphase eines Modells zur Erstellung von Vorhersagen) direkt auf dem Endgerät (dem "Edge-Device", z. B. einem Smartphone oder Sensor) stattfindet, anstatt die Daten zur Verarbeitung an einen zentralen Server zu senden (Paaß & Giesselbach, 2023).
- **Edge- und Server-Infrastruktur:** Die kombinierte technische Infrastruktur, die sowohl aus dezentralen Edge-Geräten als auch aus zentralen Servern (oft in der Cloud) besteht. Diese Architekturen definieren, wie Rechenlasten und Daten zwischen den beiden Ebenen verteilt werden (Andreoni et al., 2024; Ibrahim et al., 2024).
- **Hybride Architekturen:** Systemdesigns, die sowohl Cloud- als auch Edge-Komponenten strategisch kombinieren. Ziel ist es, die Vorteile beider Ansätze zu nutzen – beispielsweise die geringe Latenz der Edge-Verarbeitung und die hohe Rechenleistung der Cloud (Z. Li et al., 2024; Paaß & Giesselbach, 2023).

- **Latent Diffusion Models (LDMs):** Eine Klasse generativer Modelle, die den rechenintensiven Diffusionsprozess nicht im hochdimensionalen Pixelraum, sondern in einem komprimierten, niedrigdimensionalen "latenten" Raum durchführen. Dies macht sie deutlich effizienter in Training und Anwendung (Z. Li et al., 2024).
- **Offloading-Learning:** Eine Strategie in Edge-Computing-Systemen, bei der rechenintensive Aufgaben (z. B. das Training eines Modells oder komplexe Inferenzschritte) von einem ressourcenbeschränkten Edge-Gerät an einen leistungsfähigeren Server oder die Cloud "ausgelagert" (offloaded) werden (Zhou et al., 2024).
- **Stable Diffusion-Varianten:** Verschiedene Versionen und Anpassungen des populären Text-zu-Bild-Modells "Stable Diffusion". Diese Varianten können für spezifische Stile, Konzepte oder Anwendungsfälle optimiert sein und basieren auf dem ursprünglichen Open-Source-Modell (Z. Li et al., 2024).

ANLAGEN

Declaration on Identity

I, the undersigned, **Cedric Bartelt**, declare that **the printed and electronic versions** of the doctoral dissertation and thesis booklet **are identical in all respects.**

Duisburg, den 05.03.2026

signature of PhD candidate

Legal Declaration

I, the undersigned Cedric Bartelt, by signing this declaration declare that the printed and electronic version of my PhD dissertation was my own work; during the dissertation I complied with the Act LXXVI of 1999 on the rules of copyright and the rules of the doctoral dissertation prescribed by the Doctoral School, especially regarding references and citations.²¹

Furthermore, I declare that I did not mislead the supervisor (s) or the program leader with the dissertation.

By signing this declaration, I acknowledge that if it can be proved that the dissertation is not self-made or the author of a copyright infringement is related to the dissertation, the University of Sopron is entitled to refuse the acceptance of the dissertation.

I further declare that I am not in the process of obtaining a doctoral degree in the same discipline, that I am not in the process of having my doctoral degree revoked, and that I have not had a previously awarded doctoral degree revoked within 5 years.

Refusing to accept a dissertation does not affect any other (civil, legal, criminal) consequences of copyright infringement.

Duisburg, den 05.03.2026

signature of PhD candidate

²¹ LXXVI. TV. 1999 Section 34 (1) Any person may quote the details of the work, to the extent justified by the nature and purpose of the receiving work and in the original, by the name of the source and the author designated there.

Article 36 (1) Details of public lectures and other similar works, as well as political speeches, may be freely used for information purposes, within the scope justified by the purpose. For such use, the source, along with the author's name, should be indicated, unless this is impossible.

Widmung

Für meine Frau *Christine*, die diesen langen Weg mit unendlicher Geduld und Liebe an meiner Seite gegangen ist.

Für meine Tochter *Mascha*, deren Lachen die schönste Motivation war.

Und für meine Mutter *Andrea*, die von Anfang an fest an diesen Erfolg geglaubt hat.

In liebevoller Erinnerung an meinen Vater *Frank*. Ich weiß, er wäre stolz gewesen.

Duisburg, den 05.03.2026

Cedric Bartelt