

www.iu.de

IU DISCUSSION

PAPERS

IT & Engineering

KI-Kompetenzen 2026: Welche Fähigkeiten sucht der
Arbeitsmarkt?

FABIAN ZETTIER
FRANK KRICKEL
KNUT LINKE

IU Internationale Hochschule

Main Campus: Erfurt
Juri-Gagarin-Ring 152
99084 Erfurt

Telefon: +49 421.166985.23

Fax: +49 2224.9605.115

Autorenkontakt:

Fabian Zettier
ORCID-ID: 0009-0000-6357-1554 (Open Researcher und Contributor ID)
E-Mail: fabian.zettier04@gmail.com

Prof. Dr. Frank Krickel
IU Internationale Hochschule - Campus Hannover
Schiffgraben 49-51
30175 Hannover
E-Mail: frank.krickel@iu.org

Prof. Dr. Knut Linke
ORCID-ID: 0000-0001-5088-5546 (Open Researcher und Contributor ID)
IU Internationale Hochschule - Campus Hannover
Schiffgraben 49-51
30175 Hannover
E-Mail: knutlinke@gmail.com

IU Discussion Papers, Reihe: IT & Engineering, Vol. 7, No. 2 (AUG 2026)

ISSN: 2750-073X

DOI: <https://doi.org/10.56250/4142>

Website: <https://repository.iu.org>

KI-KOMPETENZEN 2026: WELCHE FÄHIGKEITEN SUCHT DER ARBEITSMARKT?

Rollencluster, Skill-Schwerpunkte und Implikationen für Recruiting & Weiterbildung

Fabian Zettier, Frank Krickel & Knut Linke

ABSTRACT:

This discussion paper investigates which generative AI (GenAI) competencies are demanded in German job advertisements and how they align with AI competency frameworks. The study combines a synthesis of 18 competency frameworks with an AI-assisted qualitative content analysis of 258 GenAI-relevant job postings from the German Federal Employment Agency's job portal (collected on 14 March 2026) using a deductive-inductive approach.

Results show a strongly technology-centric demand pattern: programming and cloud/MLOps dominate, while reflection, governance, and legal/compliance competencies remain weakly articulated despite their prominence in literature and regulatory relevance. Cluster analysis reveals three role profiles: technical engineering, application/process-oriented roles, and hybrid profiles combining technical depth with strategic integration. Inductive analysis identifies emerging competency fields not systematically covered by existing frameworks, including AI enablement and knowledge transfer, domain expertise, AI tool evaluation, human-centred design, and protocol-related integration skills.

Implications are derived for competency-based recruiting and role-specific upskilling, emphasizing the need to explicitly anchor governance and compliance capabilities alongside technical implementation expertise.

KEYWORDS:

Generative AI, German labor market, IT labor, AI competency frameworks

JEL: J24, M51, L86

AUTORS



Fabian Zettier ist Consultant für Microsoft-Copilot-Integration bei der Hamburger Beratungsfirma PHAT Consulting und studierte vorher Wirtschaftsinformatik mit Vertiefung Digital Business an der IU Internationalen Hochschule. Vor seiner aktuellen Tätigkeit war er als Online Distribution Consultant tätig, wo er sich mit dem praktischen Einsatz von Microsoft Copilot und digitalen Vertriebsprozessen beschäftigte. Seine Schwerpunkte liegen in generativer KI, digitaler Transformation, Prozessdigitalisierung und der Einführung KI-basierter Assistenzsysteme in Unternehmen.



Prof. Dr. Frank Krickel ist Professor für Wirtschaftsinformatik an der IU Internationalen Hochschule, Unternehmensberater und Coach aus Hannover. Seine Schwerpunkte liegen in digitaler Transformation, IT-Management, Organisationsentwicklung und der Digitalisierung der Energiewirtschaft. Durch seine frühere Tätigkeit als CIO der EnBW verbindet er wissenschaftliche Perspektiven mit langjähriger Führungserfahrung in der Unternehmenspraxis.



Prof. Dr. Knut Linke ist Professor für Informatik an der IU Internationalen Hochschule und Professor für Digitale Transformation, Informationstechnik und KI an der Hochschule der gesetzlichen Unfallversicherung. In Lehre und Forschung beschäftigt er sich schwerpunktmäßig mit künstlicher Intelligenz, digitaler Transformation, und digitaler Didaktik. Ein weiterer zentraler Schwerpunkt seiner Arbeit liegt darin, komplexe KI-Themen verständlich zu vermitteln und ihre Implikationen aufzuzeigen.

Ausgangslage und Forschungsfrage

Wer ChatGPT zum ersten Mal nutzt, erhält binnen Sekunden einen Bericht, einen Entwurf oder eine Antwort auf nahezu jede Frage – ohne Handbuch, Schulung oder Programmierkenntnisse. Diese niedrige Nutzungsschwelle verdeckt jedoch, wie anspruchsvoll die professionelle Implementierung, der rechtssichere Betrieb und die strategische Einbettung generativer KI (GenAI) in Unternehmensprozesse tatsächlich sind. Während Führungskräfte GenAI als strategische Priorität ausrufen, stellt sich in vielen Organisationen daher eine operative Kernfrage: Wer verfügt über die Kompetenzen, diese Technologie produktiv, verantwortungsvoll und skalierbar umzusetzen?

In kurzen Innovationszyklen erscheinen neue Modelle, Werkzeuge und produktive Anwendungsformen, die erhebliche Effizienz- und Innovationspotenziale versprechen (Büchel & Engler, 2025, S. 1; Sengar et al., 2024, S. 23662). Laut KPMG AG (2025, S. 9) setzen bereits alle befragten deutschen Unternehmen generative KI ein. Viele Initiativen verbleiben im Stadium punktueller Pilotierung; der nachhaltige Einsatz in Prozessen und Produkten entwickelt sich häufig langsamer als strategisch intendiert (Singla et al., 2025, S. 4). Ein zentraler Engpass liegt dabei weniger in der Technologie als im Kompetenzaufbau. Viele Unternehmen verfügen weder über ausreichend spezialisierte Fachkräfte noch über klar definierte Strategien, um GenAI professionell zu implementieren, zu betreiben und organisatorisch zu verankern (Rampelt, Klier, et al., 2025, S. 2). Die OECD (2024a, S. 93f.) berichtet, dass 48 Prozent der deutschen Arbeitgeber den Kompetenzmangel als wesentliches Hindernis der KI-Einführung benennen. Der Arbeitsmarkt reagiert darauf: Im Jahr 2024 wurden rund 18.000 Stellen ausgeschrieben, in denen Kompetenzen im Umgang mit generativer KI gefordert wurden; nahezu dreimal so viele wie noch 2023 (Büchel & Engler, 2025, S. 2). Der operative Flaschenhals verschiebt sich damit von der Verfügbarkeit der Technologie hin zur Fähigkeit, KI-Initiativen in einen produktiven und nachhaltigen Einsatz zu überführen.

Parallel zur wirtschaftlichen Dynamik nimmt der regulatorische Druck zu. Mit dem EU AI Act hat die Europäische Union einen umfassenden Rechtsrahmen für KI-Systeme geschaffen, der für Unternehmen und Organisationen verbindlich ist und diese zur Qualifikation ihrer Mitarbeiter verpflichtet (Hagedorn & Linke, 2025). Im Detail verpflichtet Artikel 4 Anbieter und Betreiber seit Februar 2025, sicherzustellen, dass ihr Personal über ein ausreichendes Maß an KI-Kompetenz verfügt (EU AI Act, 2024, Article 4). KI-Kompetenz wird damit von einer empfohlenen Qualifikation zu einer gesetzlichen Anforderung. Unternehmen stehen folglich vor einer doppelten Herausforderung: Sie müssen GenAI-Potenziale realisieren, um wettbewerbsfähig zu bleiben, und zugleich regulatorische, ethische sowie technische Risiken beherrschbar machen. Beides setzt voraus, dass relevante Kompetenzen in den dafür verantwortlichen Rollen tatsächlich vorhanden sind.

Trotz dieser Ausgangslage fehlt bislang ein systematischer Überblick darüber, welche Kompetenzen Fachkräfte konkret benötigen, um GenAI in Unternehmen professionell zu implementieren, zu betreiben und strategisch zu steuern. Zwar beschreiben theoretische Kompetenzrahmen umfassend, welche Fähigkeiten hierfür erforderlich sind; bestehende Stellenanzeigenanalysen liefern zudem wichtige Einblicke in den KI-Arbeitsmarkt. Beide Perspektiven bleiben jedoch häufig entweder auf KI-Kompetenzen in der Breite oder auf allgemeine Anwenderkompetenzen fokussiert und adressieren damit nur begrenzt jene Expertenrollen, die für Einführung, Integration und Betrieb generativer KI verantwortlich sind. Was bislang fehlt, ist die systematische Verbindung beider Sichtweisen: ein

theoretisch fundiertes GenAI-Kompetenzprofil, das empirisch an den Anforderungen des deutschen Arbeitsmarkts gespiegelt wird, um Übereinstimmungen und Abweichungen zwischen Forschung und betrieblicher Praxis sichtbar zu machen.

Die zentrale Forschungsfrage dieses Discussion Papers lautet daher:

Wie manifestieren sich GenAI-Kompetenzanforderungen in deutschen Stellenausschreibungen, wie verhalten sie sich zu den in der Literatur beschriebenen Kompetenzanforderungen und welche Implikationen ergeben sich daraus für Recruiting und betriebliche Weiterbildung in Unternehmen?

Zur Operationalisierung dieser Frage werden vier Unterforschungsfragen (UF) adressiert:

1. *Welche GenAI-bezogenen Kompetenzen werden in deutschen Stellenausschreibungen für rollenbezogene Expertenfunktionen (Implementierung, Betrieb, Steuerung) gefordert?*
2. *Welche typischen Kompetenzbündel bzw. Stellenprofile lassen sich auf Basis der Stellenausschreibungen identifizieren?*
3. *Inwiefern stimmen die empirisch beobachteten Kompetenzanforderungen mit dem literaturbasierten Kompetenzprofil überein und wo zeigen sich systematische Abweichungen oder Leerstellen?*
4. *Welche Implikationen ergeben sich daraus für Recruiting und betriebliche Weiterbildung in Unternehmen (ggf. auch unter Berücksichtigung regulatorischer Anforderungen, z. B. EU AI Act, Art. 4)?*

Zur Beantwortung dieser Frage wird ein zweistufiges Vorgehen verfolgt:

Erstens wird auf Basis einer systematischen Literaturanalyse ein theoretisches Kompetenzprofil entwickelt, das die in der Forschung diskutierten Anforderungen in zwölf Kategorien strukturiert.

- Zweitens werden 258 Stellenanzeigen mit explizitem GenAI-Bezug mittels KI-gestützter qualitativer Inhaltsanalyse nach Mayring (2022) ausgewertet. Eine ergänzende Clusteranalyse macht typische Kompetenzprofile auf Stellenebene sichtbar.

Bevor das zweistufige Vorgehen im Detail ausgeführt wird, sind begriffliche und konzeptionelle Grundlagen zu klären. Dies ist aus zwei Gründen erforderlich: Erstens variiert in Forschung und Praxis, was unter „generativer KI“ im Unternehmenskontext verstanden wird, erheblich, mit direkten Konsequenzen dafür, welche Tätigkeiten, Rollen und damit Kompetenzen überhaupt in den Blick geraten. Zweitens setzt der angestrebte Abgleich zwischen Literatur und Stellenausschreibungen gemeinsame Referenzpunkte voraus, um Anforderungen konsistent kodieren und vergleichen zu können. Vor diesem Hintergrund werden im folgenden Abschnitt zentrale Begriffe definiert und der Untersuchungsgegenstand konzeptionell eingegrenzt.

Begriffliche und konzeptionelle Grundlagen

Zur Eingrenzung des Untersuchungsgegenstands ist zwischen klassischer (diskriminativer) und generativer KI zu unterscheiden. Diskriminative KI-Systeme identifizieren Strukturen in Daten, klassifizieren Eingaben und leiten daraus Vorhersagen ab (Hubel et al., 2025, S. 13). Typische Anwendungen sind Klassifikationsaufgaben wie Spam-Filter (Bitkom e. V., 2025a, S. 10; Ertel, 2025, S. 23f.). Generative KI (GenAI) adressiert demgegenüber nicht primär Klassifikation, sondern die synthetische Erzeugung neuer Inhalte (z.B. Text, Bild, Audio, Code) auf Basis statistisch gelernter Muster aus großen Trainingsdatensätzen (Bendel, o. J.; Ertel, 2025, S. 351; Hubel et al., 2025, S. 13; Nettesheim, 2025, S. 91; Sengar et al., 2024, S. 23662). Dadurch kann GenAI Aufgaben unterstützen, die bislang häufig menschlichem Urteilsvermögen vorbehalten waren (Chui et al., 2024, S. 16; Sengar et al., 2024, S. 23661).

Ein zentraler Diffusionsfaktor ist die niedrigschwellige Nutzbarkeit: Im Unterschied zu früheren Softwaregenerationen ist für produktive Erstnutzung typischerweise kein vertieftes informationstechnisches Vorwissen erforderlich (Büchel & Engler, 2025, S. 1). In der Folge wird GenAI in Unternehmen zunehmend als „Wissens- und Produktivitätsinfrastruktur“ für verschiedenste Funktionsbereiche genutzt, etwa für Inhaltsproduktion, Softwareentwicklung und wissensintensive Routinetätigkeiten (Brynjolfsson et al., 2025, S. 911; vgl. Singla et al., 2025).

Es ist entscheidend, dass die Realisierung dieser Potenziale nicht allein eine Technologiefrage ist, sondern in hohem Maße von der Kompetenzverfügbarkeit abhängt. GenAI ist mit spezifischen Qualitäts-, Governance- und Organisationsrisiken verbunden (z.B. Halluzinationen, Black-Box-Charakter, unkritische Übernahme von Ausgaben), die ohne geeignete Qualifizierung zu Fehlentscheidungen und Folgeschäden führen können (Greiner et al., 2024, S. 58; Kissin, 2025; Nettesheim, 2025, S. 91; Zhang & Magerko, 2025, S. 2). Damit verschiebt sich der analytische Fokus von der reinen Nutzbarkeit hin zur Frage, welche Kompetenzen erforderlich sind, um GenAI in Unternehmen verantwortungsvoll, prozessintegriert und wertschöpfend zu implementieren.

KOMPETENZBEGRIFF UND AI LITERACY

Die arbeitsmarktorientierte Analyse von GenAI-Anforderungen setzt eine begriffliche Klärung von Wissen, Fähigkeiten und Kompetenz voraus. Wissen bezeichnet das verfügbare theoretische bzw. faktische Verständnis (z. B. Funktionsprinzipien von LLMs) und ist notwendige, aber nicht hinreichende Grundlage kompetenten Handelns (Erpenbeck et al., 2021, S. 30ff.). Fähigkeiten beschreiben die operative Umsetzung dieses Wissens in konkreten Handlungen, wie z. B. Prompt-Formulierung oder Programmierung (Erpenbeck et al., 2021, S. 29; Myszak & Filina-Dawidowicz, 2025, S. 4). Kompetenz integriert Wissen und Fähigkeiten und ergänzt sie um psychosoziale Komponenten, wie Einstellungen, Werte oder auch Motivation, zur situationsgerechten Problemlösung in einem Kontext (Erpenbeck et al., 2021, S. 29; Myszak & Filina-Dawidowicz, 2025, S. 4). Da die einschlägige Literatur zu GenAI-Anforderungen diese Ebenen häufig überblendet, wird im Folgenden „Kompetenz“ als Sammelbegriff verwendet, sofern ein Bezug zu arbeits- und organisationsbezogenem Handeln gegeben ist.

Vor diesem Hintergrund lässt sich AI Literacy als grundlegende, aber nicht hinreichende Kompetenzbasis für den Umgang mit KI einordnen. AI Literacy umfasst Fähigkeiten, KI-Systeme zu verstehen, kritisch zu beurteilen und zweckmäßig zu nutzen (Long & Magerko, 2020, S. 2). Zentral sind

dabei technisches Grundverständnis, kritische Bewertung und praktische Anwendung (Laupichler et al., 2023, S. 2), typischerweise aufbauend auf Digital und Data Literacy (Gimpel et al., 2024, S. 13; Greiner et al., 2024, S. 12f.). Entsprechend wird AI Literacy in Teilen der Literatur als primär nutzungs- und reflexionsorientiert charakterisiert und nicht als tieftechnische Qualifikation (Armutat et al., 2025, S. 2).

Für GenAI ist eine bloße Übertragung bestehender Literacy-Konzepte jedoch nur begrenzt tragfähig, da generative Systeme andere Interaktions- und Qualitätsprobleme erzeugen (z.B. probabilistische Ausgaben, Kontextsteuerung, Ergebnisvalidierung). Daher wird ein spezifisches Kompetenzprofil diskutiert, das u.a. Werkzeugauswahl, Prompting, Interaktionsverständnis, kritische Ergebnisbewertung sowie ein übergeordnetes Technologieverständnis umfasst (Annapureddy et al., 2025, S. 2; Zhang & Magerko, 2025, S. 1ff.). Die vorliegende Arbeit schließt daran an, fokussiert jedoch explizit nicht auf basale Nutzungsbefähigung (GenAI Literacy im engeren Sinne), sondern auf Kompetenzanforderungen, die die professionelle Einführung, Integration, Steuerung und Governance generativer KI im Unternehmenskontext ermöglichen (Armutat et al., 2025, S. 2; Baumgartner et al., 2023, S. 4; Lorenz et al., 2025, S. 3).

REGULATORISCHER RAHMEN UND DIE ROLLE VON HR

Mit dem EU AI Act hat die Europäische Union einen risikobasierten Regulierungsrahmen etabliert, der KI-Systeme nach ihrem Gefährdungspotenzial klassifiziert und daraus abgestufte Anforderungen an Transparenz, Dokumentation und menschliche Aufsicht ableitet (Bitkom e. V., 2025a, S. 17; EU AI Act, 2024). Für Unternehmen ist insbesondere Artikel 4 relevant, der Anbieter und Betreiber verpflichtet, sicherzustellen, dass Beschäftigte über ein ausreichendes Maß an KI-Kompetenz verfügen; die Anforderungen variieren dabei je nach Rolle, Vorerfahrung und Einsatzkontext (EU AI Act, 2024, Article 4; Fraunhofer FIT, 2025). Damit wird KI-Kompetenz zu einer organisationsweiten Compliance-Anforderung, die nicht auf technische Spezialisten begrenzt ist, sondern grundsätzlich alle Mitarbeitenden betrifft, die KI-Systeme nutzen oder verantworten (Fraunhofer FIT, 2025).

Neben dem EU AI Act prägt insbesondere die DSGVO die betriebliche Einsatzfähigkeit von KI. Sie fordert eine rechtmäßige Verarbeitung personenbezogener Daten und begrenzt vollständig automatisierte Entscheidungen mit erheblichen Auswirkungen durch Artikel 22 (DSGVO, 2016, Article 22). Im Kontext generativer KI ergeben sich daraus u.a. Fragen zur Zulässigkeit von Dateneingaben in Modelle, zu Haftungs- und Verantwortlichkeitsstrukturen sowie zu urheber- und compliancebezogenen Risiken (Bitkom e. V., 2025a, S. 46; Greiner et al., 2024, S. 91f.). Regulatorik wirkt damit nicht nur als Restriktion, sondern als externer Treiber für systematischen Kompetenzaufbau und belastbare Governance-Strukturen.

Hieraus folgt eine zentrale Rolle der Personalfunktion: HR ist über Recruiting und Weiterbildung unmittelbar in der Lage, die für regulatorisch-konformen und zugleich wertschöpfenden KI-Einsatz notwendige Kompetenzbasis aufzubauen und organisational zu verankern (André & Bauer, 2021, S. 10; Nettesheim, 2025, S. 316f.). Der Wandel wird als Übergang von administrativem hin zu strategisch-proaktivem HR beschrieben, das Belegschaftsentwicklung, Geschäftsstrategie und KI-Einsatz integriert (Kirchherr et al., 2025, S. 5). Da Jobtitel im dynamischen GenAI-Umfeld an Trennschärfe verlieren, gewinnt eine kompetenzbasierte Personalstrategie an Bedeutung, die konkrete Fähigkeiten

identifiziert, entwickelt und bedarfsgerecht allokiert (André & Bauer, 2021, S. 10; Kirchherr et al., 2025, S. 13f.).

Zur Schließung von Kompetenzlücken werden typischerweise drei Ansätze kombiniert: Upskilling des Bestandspersonals, Recruiting spezialisierter Fachkräfte und externe Unterstützung (Chui et al., 2024, S. 35; Morandini et al., 2023, S. 53). Stellenausschreibungen sind in diesem Zusammenhang als empirische Datenquelle besonders geeignet, da sie reale, budgetierte Kompetenznachfrage abbilden und damit einen belastbaren Indikator für die Praxisprioritäten darstellen (Daly et al., 2024, S. 19; Deming & Kahn, 2017, S. 4f.). Ihre systematische Auswertung erlaubt es, theoretische Kompetenzprofile mit arbeitsmarktlichen Anforderungen abzugleichen und Abweichungen zwischen normativen Rahmenwerken (inkl. regulatorischer Pflichten) und betrieblicher Umsetzung sichtbar zu machen (Daly et al., 2024, S. 19; Deming & Kahn, 2017, S. 4f.).

GenAI-Kompetenzanforderungen: Stand der Forschung

Empirische Studien weisen übereinstimmend auf substanzielle Defizite bei KI-Kompetenzen in deutschen Unternehmen hin. Die Evidenz speist sich dabei primär aus Unternehmensbefragungen, welche Selbsteinschätzungen von Führungskräften und Beschäftigten abbilden, sowie Analysen von Online-Stellenanzeigen, die arbeitsmarktseitige Nachfrage nach Kompetenzen operationalisieren.

Auf Basis von Unternehmensbefragungen zeigt sich ein konsistentes Bild: 79% der befragten Führungskräfte berichten fehlende grundlegende KI-Kompetenzen in der Belegschaft (Rampelt, Klier, et al., 2025, S. 5). In einer Bitkom-Umfrage nennen 53% der Unternehmen fehlendes technisches Know-how als zentrales Hemmnis des KI-Einsatzes (Bitkom e.V., 2025b). OECD-Daten verorten den Kompetenzmangel bei 48% der deutschen Arbeitgeber als wesentliches Implementierungshemmnis – über dem Niveau vergleichbarer Länder (OECD, 2024a, S. 93f.). Besonders betroffen sind kleine und mittlere Unternehmen, denen häufig Ressourcen und Attraktivität fehlen, um KI-Talente zu gewinnen und Anwendungen zu identifizieren, zu entwickeln und zu betreiben (OECD, 2024a, S. 56).

Die Lücke betrifft nicht nur vertiefte technische Qualifikationen, sondern bereits Basiskonzepte. Zwischen 40% und 60% der befragten erwachsenen Erwerbstätigen in Europa verfügen über ein schwaches Verständnis davon, was KI ist, wie sie funktioniert und welche gesellschaftlichen Folgen sie haben kann (Cedefop, 2025, S. 19). Für GenAI zeigt die KPMG-Studie, dass nur 17% der Unternehmen überzeugt sind, die für produktive Nutzung erforderlichen Kompetenzen seien vorhanden (KPMG AG, 2025, S. 64). Zudem berichten 54% der KI-Nutzenden, durch KI nicht besser in ihrem Job geworden zu sein; in dieser Gruppe sind Personen mit geringerer KI-Kompetenz überrepräsentiert (Cedefop, 2025, S. 24). Diese Befunde sprechen dafür, dass fehlende Kompetenz nicht nur die Einführung, sondern auch den realisierten Nutzen begrenzt.

Stellenanzeigenanalysen bestätigen eine substanzielle, jedoch differenzierte Nachfrageentwicklung. Zwar stieg die Anzahl KI-bezogener Stellenanzeigen von 97.000 (2019) auf 181.000 (2022), fiel bis 2024 jedoch auf ca. 152.000 und entspricht damit nur rund 1,5% des Gesamtmarkts (Büchel et al., 2025b, S. 6). Gleichzeitig bleiben KI-Stellen in Deutschland länger unbesetzt als Stellen in anderen Sektoren, etwa im Gesundheitswesen oder im verarbeitenden Gewerbe (OECD, 2024a, S. 29). Zur Präzisierung ist jedoch zwischen (a) der allgemeinen Arbeitsmarktnachfrage nach KI-Kompetenzen und (b) dem Teilmarkt der GenAI-bezogenen Anforderungen zu unterscheiden. Der aggregierte Rückgang

kann wesentlich durch ein Nachlassen breit gefasster bzw. allgemeiner KI-Anwenderanforderungen erklärt werden, während GenAI als jüngerer und dynamischer Teilbereich gegenläufige Trends aufweist. So wurden 2024 rund 18.000 Stellenanzeigen mit expliziten Anforderungen an den Umgang mit generativer KI veröffentlicht – nahezu dreimal so viele wie 2023 (Büchel & Engler, 2025, S. 2). Ergänzend zeigen Auswertungen, dass GenAI- bzw. Prompting-Kenntnisse in den Jahren 2023/2024 in über 25.000 Stellenanzeigen als Zusatzanforderung innerhalb etablierter Rollen (z.B. Data Science, Marketing, Consulting) adressiert wurden (Engler, 2025, S. 3). Der empirische Befund ist somit als parallele Entwicklung zweier Ebenen zu interpretieren: Während der KI-Arbeitsmarkt in der Breite zuletzt eher stagnierte bzw. leicht zurückging, expandiert der GenAI-bezogene Teilmarkt – insbesondere dort, wo Anforderungen an Implementierung, Integration und produktiven Betrieb adressiert werden.

URSACHEN DER KOMPETENZLÜCKE

Der Kompetenzbedarf generativer KI ist durch ein strukturelles Spannungsverhältnis geprägt: Während der Zugang über Chat-Interfaces niedrigschwellig erscheint, ist der professionelle, sichere und wertschöpfende Einsatz im Unternehmenskontext technisch, organisatorisch und rechtlich komplex. Die Lücke entsteht daher weniger durch „fehlende Tool-Bedienung“, sondern durch Defizite entlang des gesamten Lebenszyklus von Planung, Integration, Betrieb und Governance.

Technische Integrations- und Betriebsanforderungen

GenAI-Anwendungen müssen in bestehende, häufig heterogene und legacy-geprägte IT-Landschaften integriert werden. Diese Einbettung erfordert spezialisiertes Wissen, das in vielen Organisationen nicht ausreichend verfügbar ist (Hughes et al., 2026, S. 5; Mackensen et al., 2024, S. 17; Prasad Agrawal, 2024, S. 646f.). Zudem verfügen Basismodelle nicht über unternehmensspezifisches Domänen- und Prozesswissen; produktive Nutzung setzt daher ergänzende Architekturen und Mechanismen zur Anbindung von Firmenwissen voraus (Bitkom e.V., 2026, S. 34f.; Greiner et al., 2024, S. 38; Hubel et al., 2025, S. 15).

Unterschätzte Einführungskomplexität und strategische Verankerung

In vielen Unternehmen wird GenAI-Einführung weiterhin primär als IT-Projekt gerahmt, während Prozessanpassungen, kultureller Wandel und systematische Befähigung vernachlässigt werden (Hughes et al., 2026, S. 1f.; Mackensen et al., 2024, S. 20; Cedefop, 2025, S. 25). Damit verbunden ist eine Fehleinschätzung des Qualifizierungsbedarfs: Führungskräfte priorisieren GenAI zwar strategisch, stellen jedoch häufig nicht ausreichend Budget und Struktur für Weiterbildung bereit (Hughes et al., 2026, S. 2ff.; Rampelt, Klier, et al., 2025, S. 7). Zudem fehlt vielfach eine konsistente Kompetenzstrategie, die KI-Kompetenzen systematisch in Personalplanung und Organisationsentwicklung integriert (Kirchherr et al., 2025, S. 7f.; Rampelt, Klier, et al., 2025, S. 7).

Weiterbildungsdefizite und Nutzungsbarrieren auf Mitarbeiterebene

Ein großer Teil der europäischen Erwerbstätigen hat bislang keine formale GenAI-Schulung erhalten. Im Vergleich erhielten in den USA 45 % der Beschäftigten entsprechende Trainings, in Europa lediglich 21 % (Kirchherr et al., 2025, S. 22). Randstad berichtet ebenfalls ein strukturelles Missverhältnis: Obwohl 75 % der Unternehmen KI einführen, erhielt nur ein Drittel der Beschäftigten im letzten Jahr eine

passende Schulung (Adebayo, 2025). Entsprechend fällt die regelmäßige Nutzung in Europa niedriger aus (36%) als in den USA (76%) (Kirchherr et al., 2025, S. 22). Neben Qualifikationsdefiziten wirken zudem Akzeptanz- und Kontrollbedenken, etwa die Sorge, Kontrolle über KI-gestützte Entscheidungen zu verlieren (Nettesheim, 2025, S. 64).

Damit ist die Kompetenzlücke als Zusammenspiel technischer Implementierungskomplexität, unzureichender organisationaler Investitionen und begrenzter Qualifizierungspraxis zu verstehen.

KI-KOMPETENZANFORDERUNGEN IN DER LITERATUR

Die Forschung zu KI- und GenAI-Kompetenzen hat in den letzten Jahren eine Vielzahl von Kompetenzrahmen hervorgebracht. Konsens besteht in den Modellen so weit darin, dass produktiver GenAI-Einsatz ein mehrdimensionales Profil erfordert, das technische, organisatorisch-strategische sowie reflexive und normative Komponenten integriert.

Zur Strukturierung dieser Anforderungen werden im folgenden Kompetenz-Frameworks herangezogen, die im Zuge der Literatursuche identifiziert und als für die Untersuchung thematisch einschlägig beurteilt wurden. Berücksichtigt wurden Quellen aus zitierfähigen, wissenschaftlich zugänglichen Publikationsmedien (z. B. Fachzeitschriften, Konferenzbeiträge, Berichte/Publicationen etablierter Institutionen). Die so berücksichtigten Frameworks decken unterschiedliche Perspektiven ab und werden in Tab. 1 überblicksartig zusammengeführt.

Gimpel et al. (2024) strukturieren Kompetenzen entlang der Dimensionen KI-Technologie, KI-Entwicklung und -Betrieb, KI-Anwendung, KI-Management sowie KI-Reflexion und verdeutlichen damit die Relevanz betriebswirtschaftlicher Steuerung und ethisch-rechtlicher Reflexion neben technischen Grundlagen. Der AWIKI-Rahmen differenziert korrespondierend fünf Kompetenzarten (technisch, Daten, Fach, juristisch, ethisch-reflexiv) und operationalisiert diese zusätzlich über konkrete Projektrollen (Lorenz et al., 2025). Spezifisch für GenAI adressieren neuere Modelle die besonderen Interaktions- und Qualitätsprobleme generativer Systeme: Annapureddy et al. (2025) skizzieren einen Lernpfad von Grundlagenwissen über Prompting und Output-Bewertung bis zu Ethik und Recht (Annapureddy et al., 2025). Zhang und Magerko (2025) fokussieren u. a. Werkzeugauswahl, Prompting, Interaktionsverständnis und das Verständnis von Ausgaben (Zhang & Magerko, 2025). Ergänzend zielen organisationszentrierte Frameworks auf die Brücke zwischen individuellen Fähigkeiten und organisationaler Implementierung, etwa durch Governance- und Change-Perspektiven (Weinberg, 2025). Rollenbasierte Rahmungen betonen, dass Kompetenzanforderungen nach Verantwortungsniveau variieren: Das AI Skills for Business Framework unterscheidet u. a. „AI Leaders“ und erwartet dort insbesondere strategische Steuerung, rechtliche Standards und Evaluation, während technische Rollen stärker in Engineering- und Betriebsanforderungen differenzieren (The Alan Turing Institute et al., 2026).

Die in Tabelle 1 zusammengeführten Kompetenzframeworks zeigen einen breiten Konsens darüber, dass professioneller KI- bzw. GenAI-Einsatz ein mehrdimensionales Kompetenzprofil erfordert. Zugleich unterscheiden sich die Modelle jedoch deutlich hinsichtlich Zielgruppe (z.B. allgemeine Anwenderkompetenzen vs. Professional-/Leader-Profil), Strukturprinzip (verhaltens-, rollen- oder organisationsbezogen) sowie Granularität (wenige Dimensionen bis hin zu umfangreichen Kompetenzlisten).

Tab. 1: Überblick KI-Kompetenzframeworks

Kategorie	Quelle	Struktur & Fokus
Verhaltens-orientiert	[1] (Gimpel, 2024)	6 Bereiche: KI-Technologie, KI-Entwicklung & -Betrieb, KI-Anwendung, KI-Management, KI-Reflexion + Grundlagen der Wirtschaftsinformatik
	[2] (Annapureddy et al., 2025)	12-Kompetenzen-Modell: Lernpfad für GenAI von Basisverständnis über Prompting und Programmierung bis hin zu Ethik & Recht
	[3] (Zhang & Magerko, 2025)	4 Aspekte (12 Richtlinien): GenAI-Werkzeugauswahl & Prompting, Verständnis der Interaktion, Ausgaben und der Technologie
	[4] (Ehlers et al., 2023)	AICOMP: 3 Handlungsfelder mit 13 Profilen, basierend auf KSAVE-Modell (Knowledge, Skills, Attitudes/Values)
	[5] (Onnen, 2024)	Integration in bestehende Modelle: 4 Kernbereiche (Digital Literacy, Ethical Leadership, Data-driven Decision-making, Change-Management)
	[6] (Grimberg & Mason, 2025)	GenAI Proficiency Framework: 3 Dimensionen (Effektives Prompting, informierte/verantwortungsvolle Entscheidungen, komplexe Nutzung)
	[7] (Neuhaus et al., 2024)	5 Kompetenzfelder: aufgaben-, konzept-, system-, interaktions- und konsequenzbezogen (aufgeteilt in Basis-, befähigende und vertiefende Kompetenzen)
Rollen-basiert	[8] (The Alan Turing Institute et al., 2026)	AI Skills for Business: 4 Personas (AI Citizens, Workers, Professionals, Leaders) bewertet in 5 Dimensionen
	[9] (Ahuja, 2024)	Skills-Based Hiring: 43 allgemeine und 14 technische KI-Kompetenzen, spezifisch aufgeschlüsselt nach Gehalts- und Erfahrungsstufen
	[10] Kupa et al. (2025)	Kompetenzdreieck: 3 Rollen (Nutzer, Entscheider, Techniker) + Rollenübergreifende Kompetenzen
	[11] (Di Vinadio et al., 2022)	KI im öffentlichen Sektor: 3 Domänen (Digitale Planung, Datennutzung, Digitales Management), 5 Haltungen (z.B. Neugier, Vertrauen) + "AI-spezifische Stufe"
	[12] (Europäische Kommission et al., 2025)	DigComp 3.0: 5 Kompetenzbereiche, 21 Einzelkompetenzen, 4 Niveaus. Systematische Integration von KI als "AI-Explicit" und "AI-Implicit"
Organi-sations-spezifisch	[13] (Armutat et al., 2025)	GenAI Competency Framework & Maturity Model: 18 Kompetenzen in 3 Dimensionen (digital/technologisch, sozial, kognitiv) über 3 Reifegrade der Nutzung gemappt
	[14] (Lorenz et al., 2025)	AWIKI KI-Kompetenzrahmen: 10 konkrete Projekt-Rollen bewertet in 5 Kompetenzarten (technisch, Daten, Fach, juristisch, ethisch-reflexiv) über 3 Niveaus
	[15] (Weinberg, 2025)	FAIGMOE-Framework für GenAI: 4 Phasen zur Adaption (Strategic Assessment, Planning/Use Case, Implementation, Operationalization) speziell für Mittelstand
	[16] (Baumgartner et al., 2023)	Phasenbasierte KI-Kompetenzen: Trennung der Bedarfe "vor" vs. "während/nach" der KI-Einführung. 4 Kategorien (KI-spezifisch, Führung, Grundlegend, Anwendung)
	[17] (Rampelt, Matthes, et al., 2025)	Future Skills 2030: 30 Skills. Breite Basis (transformativ, gemeinschaftlich, digital) + 6 technologische KI-Spitzenkompetenzen (z.B. AI Engineering, Change Mgmt)
	[18] (André & Bauer, 2021)	Plattform Lernende Systeme: Prozess zum Aufbau von 3 KI-Kompetenzkategorien (Fachwissen, Umgang mit KI, Kontextgestaltung) im Change-Management

Für den in dieser Arbeit angestrebten empirischen Abgleich mit Stellenausschreibungen sind die Frameworks damit nicht ohne Weiteres als Kategoriensystem einsetzbar: Einzelne Kompetenzbegriffe sind teils unterschiedlich benannt, semantisch überlappend oder auf Abstraktionsebenen formuliert, die in Stellenanzeigen nicht konsistent beobachtbar sind. Um Anforderungen aus Literatur und Arbeitsmarkt dennoch vergleichbar zu machen, wird daher eine konsolidierte und operationalisierbare Kategoriensystematik abgeleitet.

Die Ableitung folgt drei Prinzipien:

- Erstens orientiert sich die Systematisierung am Untersuchungsfokus der Arbeit, d.h. an Expertenrollen, die GenAI in Organisationen implementieren, betreiben und steuern; grundlegende Nutzungskompetenzen im Sinne einer allgemeinen GenAI-Literacy werden daher nicht als eigenständiges Kompetenzfeld ausgewiesen, sondern nur insofern berücksichtigt, wie sie in Stellenausschreibungen für entsprechende Rollen als Anforderung formuliert werden.
- Zweitens werden in den Frameworks inhaltlich ähnliche bzw. synonym verwendete Kompetenzen gebündelt, um trennscharfe Kategorien zu erhalten und Doppelcodierungen zu vermeiden.
- Drittens werden GenAI-spezifische Anforderungen, die in mehreren neueren Arbeiten hervorgehoben werden (z.B. Prompting, Output-Validierung, modellbezogene Anpassungen), als eigenständige Kompetenzfelder abgebildet, sofern sie für Implementierung und Betrieb relevant sind.

Kompetenzen, die lediglich in einzelnen Frameworks genannt wurden, wurden nicht automatisch als eigenständige Kompetenzfelder übernommen. Sie wurden zunächst daraufhin geprüft, ob sie für den Untersuchungsfokus auf Implementierung, Betrieb und Steuerung generativer KI eine eigenständige analytische Relevanz besitzen oder ob sie semantisch sinnvoll einem bestehenden Feld zugeordnet werden können. Ein eigenes Kompetenzfeld wurde nur dann gebildet, wenn eine Anforderung entweder in mehreren Frameworks wiederkehrte, für den professionellen GenAI-Einsatz im Unternehmenskontext eine zentrale Funktion einnimmt oder gegenüber den übrigen Feldern hinreichend trennscharf operationalisierbar war.

Bei Kompetenzen, die inhaltlich zwischen zwei Feldern lagen, war für die Zuordnung nicht allein die Begrifflichkeit ausschlaggebend, sondern die im jeweiligen Arbeitskontext dominierende Funktion der Anforderung. So wurden etwa rechtliche Normkenntnisse primär K12 zugeordnet, während deren Übersetzung in organisationale Regeln, Rollen und Kontrollstrukturen unter K11 gefasst wurde. Anforderungen an Prompting wurden K5 zugeordnet, sofern die Steuerung generativer Ausgaben im Vordergrund stand; bezogen sie sich hingegen auf die Bewertung geeigneter Einsatzszenarien oder die Auswahl von Werkzeugen, wurden sie je nach Kontext K6 oder den induktiv identifizierten Ergänzungsfeldern zugeordnet. Diese Zuordnungslogik diente dazu, die Kategorien theoretisch anschlussfähig und zugleich für die Analyse von Stellenanzeigen empirisch handhabbar zu halten.

Aus dieser Konsolidierung lassen sich drei übergreifende Kompetenzbereiche ableiten: (1) technologisch-operative Kompetenzen, (2) prozessual-strategische Managementkompetenzen und (3) reflexive, ethische und rechtliche Kompetenzen. Die folgenden Abschnitte strukturieren die hergeleiteten Anforderungen entlang dieser drei Bereiche und operationalisieren sie in zwölf

Kompetenzfeldern (K1–K12) (vgl. Tab. 2). Tabelle 2 dokumentiert zugleich, welche der in Tabelle 1 aufgeführten Frameworks zur Herleitung der jeweiligen Kompetenzfelder herangezogen wurden.

Tab. 2: GenAI Kompetenzübersicht (Eigene Darstellung)

Kompetenzbereich	Kompetenzfeld	Fähigkeiten & Wissen	Quellen
Technologie & Entwicklung	K1 - Datenkompetenz & Data Science	Data Science, Big Data, Datenanalyse, SQL, Datenbankmanagement, Datenaufbereitung	[1], [5], [7], [8], [9], [10], [11], [12], [13], [14], [16], [17], [18]
	K2 - Programmierung	Python, R, Java, C/C++, Scala, Softwareentwicklung, Datenpipelines, API-Integration	[1], [2], [5], [7], [8], [9], [10], [12], [14], [15], [16], [17], [18]
	K3 - IT-Infrastruktur, Cloud & MLOps	Cloud-Computing (AWS, Azure, Google Cloud), Systemarchitektur, KI-Frameworks, MLOps, CI/CD	[1], [7], [8], [10], [14], [15], [17], [18]
	K4 - Modellentwicklung & Fine-Tuning	TensorFlow, PyTorch, Fine-Tuning, Modellanpassung, RAG, Transfer Learning, LLM-Anpassung	[1], [2], [7], [8], [10], [14], [15], [16], [17], [18]
	K5 - Prompt Engineering	Prompting, Few-Shot, Chain-of-Thought, Eingabeoptimierung, Modellsteuerung	[1], [2], [3], [6], [8], [10], [12], [13], [15]
Management & Strategie	K6 - KI-Strategie & Use-Case-Identifikation	KI-Strategie, Use Case Identifikation & Bewertung, Business Development, ROI von KI-Projekten	[1], [4], [5], [7], [8], [10], [11], [14], [15], [16], [17], [18]
	K7 - Prozessintegration & Systemdenken	Prozessoptimierung, Business Process Reengineering, Mensch-KI-Kollaboration, Cross-funktionale Koordination	[1], [4], [5], [8], [10], [11], [12], [13], [14], [15], [16], [17], [18]
	K8 – Change-Management & Führung	Change-Management, Transformationale Führung, Agilität, Resilienz, Akzeptanzförderung,	[1], [5], [7], [8], [9], [10], [11], [14], [15], [16], [17], [18]
	K9 - Agiles Projekt- & Innovationsmanagement	Scrum, Kanban, iteratives Vorgehen, interdisziplinäre Teamkoordination	[1], [4], [5], [7], [8], [9], [10], [11], [13], [14], [15], [16], [17], [18]
Reflexion, Ethik & Recht	K10 - Kritische Reflexion & Output-Bewertung	Kritisches Denken, Media Literacy, Faktenprüfung, Halluzinationen erkennen, Output-Validierung	[1], [2], [3], [4], [5], [6], [7], [8], [10], [11], [12], [13], [14], [15], [17], [18]
	K11 - KI-Governance & Ethik	Governance-Strukturen, Fairness, Erklärbarkeit, Nicht-Diskriminierung, ethische Richtlinien	[1], [4], [5], [7], [8], [10], [11], [14], [15], [16], [18]
	K12 - Juristische Kompetenzen & Compliance	EU AI Act, Datenschutz (DSGVO), Urheberrecht (Copyright), Compliance, Haftungsfragen, Informationssicherheit	[1], [2], [5], [7], [8], [10], [11], [12], [14], [15], [16], [18]

TECHNOLOGIE & ENTWICKLUNG

Der Kompetenzbereich Technologie und Entwicklung umfasst Handlungsfähigkeit zum Verständnis sowie zur Entwicklung, Anpassung und zum Betrieb generativer KI-Systeme im Unternehmenskontext. Die Literatur differenziert hierzu insbesondere Daten- und Systemkompetenzen, modellbezogene Kompetenzen sowie Prompt Engineering als Schnittstellenkompetenz; daraus werden die Kategorien K1 bis K5 abgeleitet.

Daten- und Infrastrukturkompetenzen (K1–K3). Für GenAI sind Data-Science- und Datenmanagementkompetenzen zentral, einschließlich der Aufbereitung strukturierter und unstrukturierter Daten zur Kontextualisierung und Nutzung (André & Bauer, 2021, S. 18; Lorenz et al., 2025, S. 7). Effektives Datenmanagement gilt als zentrale Voraussetzung produktiven KI-Einsatzes (Di Vinadio et al., 2022, S. 60). Programmierkompetenzen – insbesondere in Python, ergänzend u. a. R, Java oder Scala – bilden die Grundlage für Datenpipelines, Evaluation und Integration in bestehende Systeme (Annapureddy et al., 2025, S. 10; Baumgartner et al., 2023, S. 4). Für Implementierung und Betrieb werden zudem systembezogene Kompetenzen benötigt, etwa Cloud-Infrastrukturen (AWS/Azure) und KI-Frameworks (Neuhaus et al., 2024, S. 480; Weinberg, 2025, S. 7). Der produktive Betrieb erfordert MLOps-Kompetenz, einschließlich CI/CD und Monitoring (Gimpel, 2024, S. 9).

Modellentwicklung (K4). Fortgeschrittene Nutzung umfasst Fine-Tuning vortrainierter Modelle auf domänenspezifischen Daten (Annapureddy et al., 2025, S. 10; Gimpel et al., 2024, S. 9). Zur Reduktion typischer Fehlerbilder rücken Architekturen wie Retrieval-Augmented Generation (RAG) in den Fokus; ergänzend werden Kompetenzen zur Erklärbarkeit (Explainable AI) adressiert (Neuhaus et al., 2024, S. 481).

Prompt Engineering (K5). Prompt Engineering wird als GenAI-spezifische Kompetenz hervorgehoben (Annapureddy et al., 2025, S. 9; Zhang & Magerko, 2025, S. 5). Im Implementierungskontext umfasst dies nicht nur Formulierung, sondern auch strukturierte Verfahren (z. B. Few-Shot) und die Gestaltung nachvollziehbarer Herleitungen (Annapureddy et al., 2025, S. 12; Kupi et al., 2025, S. 20). Effektives Prompting setzt zudem präzise Kontextualisierung und Terminologie voraus (Grimberg & Mason, 2025, S. 10) und wird in fortgeschrittenen Szenarien über APIs und Prompt-Ketten in Prozesse automatisiert integriert (Annapureddy et al., 2025, S. 12; Greiner et al., 2024, S. 142).

MANAGEMENT & STRATEGIE

Die Implementierung generativer KI ist in vielen Anwendungsfällen weniger ein isoliertes Technologie- als ein Transformationsvorhaben. Entsprechend bündelt die Literatur „KI-Management“ u. a. in Strategie, Innovation und Transformation (Gimpel et al., 2024, S. 11). Hieraus werden K6 bis K9 abgeleitet.

Strategie und Use-Case-Kompetenz (K6). GenAI erfordert Entscheidungen über Make-or-Buy, Datenumgang und Zielsysteme, die mit Unternehmensstrategie und Governance zu synchronisieren sind (Greiner et al., 2024, S. 95; Neuhaus et al., 2024, S. 480f.; Wildhirt et al., 2025, S. 121). Als Kernkompetenz gilt die Fähigkeit, Potenziale für Geschäftsmodelle zu identifizieren und strategisch zu operationalisieren (Gimpel et al., 2024, S. 11; The Alan Turing Institute et al., 2026). Die Evaluation und Priorisierung geeigneter Use Cases wird als erfolgskritisch hervorgehoben (Weinberg, 2025), da

andernfalls Implementierungen ohne belastbare Wertbeiträge riskieren, in Pilotlogiken zu verbleiben (Baumgartner et al., 2023).

Prozessintegration und Systemdenken (K7). Effektive GenAI-Nutzung erfordert die (Neu-)Gestaltung von Prozessen im Sinne eines Business Process Reengineering (Weinberg, 2025, S. 9) sowie die Fähigkeit, System- und Kanalzusammenhänge zu verstehen („system competence“) (Ehlers et al., 2023, S. 235). Prozessdesign ist zudem Voraussetzung, um Mensch-KI-Kollaboration sinnvoll zu strukturieren (Kupi et al., 2025, S. 20).

Change-Management und Führung (K8). Die Einführung verändert Rollen, Routinen und Entscheidungslogiken; Widerstände müssen aktiv bearbeitet werden (Neuhaus et al., 2024, S. 481; Onnen, 2024, S. 13). Eine frühe Einbindung zukünftiger Anwender wird als zentral beschrieben, um Akzeptanz zu fördern und Ängste abzubauen (Baumgartner et al., 2023, S. 4f.). Subjektive Substitutionssorgen sind im Kontext GenAI empirisch relevant (Nettesheim, 2025, S. 64).

Projekt- und Innovationsmanagement (K9). GenAI-Implementierungen verlaufen typischerweise iterativ und erfordern interdisziplinäre Koordination; entsprechend werden agile und klassische Projektmanagementfähigkeiten genannt (Kupi et al., 2025, S. 20) und als eigenständiger Kompetenzbereich im KI-Kontext geführt (Gimpel et al., 2024, S. 11).

REFLEXION, ETHIK & RECHT

Reflexive, ethische und rechtliche Kompetenzen sind integraler Bestandteil professioneller GenAI-Implementierung, da generative Systeme probabilistisch arbeiten, schwer vollständig kontrollierbare Outputs erzeugen und in ein anspruchsvolles Regulierungsumfeld eingebettet sind. Daraus werden K10 bis K12 abgeleitet.

Kritische Output-Bewertung (K10). Fachkräfte müssen GenAI-Ausgaben systematisch auf Korrektheit, Relevanz und Verzerrungen prüfen. Die Literatur betont hierfür Verifikationsmethoden als Kernbestandteil von KI-Kompetenz (Greiner et al., 2024, S. 118) sowie explizit die Bewertung von Halluzinationen, Bias und Angemessenheit (Kupi et al., 2025, S. 17). KI-Reflexion wird zudem als eigenständiger Kompetenzbereich konzipiert, der Auswirkungen multiperspektivisch berücksichtigt (Gimpel et al., 2024, S. 11).

Governance und Ethik (K11). Ethisches Bewusstsein muss in Policies, Rollen und Prozesse übersetzt werden. Kompetenzrahmen adressieren hierzu Governance-Modelle sowie Prinzipien wie Fairness, Erklärbarkeit und Nicht-Diskriminierung (Gimpel et al., 2024, S. 11). Bitkom e.V. (2025a, S. 83) betonen die Notwendigkeit, ethische Prinzipien in verbindliche Regeln zu überführen; Governance und Risikomanagement werden als Voraussetzung normativer Absicherung hervorgehoben (Kupi et al., 2025, S. 24; Neuhaus et al., 2024, S. 481).

Recht und Compliance (K12). Mit EU AI Act und DSGVO entstehen Anforderungen, die nicht nur Wissen, sondern Umsetzungsfähigkeit im organisationalen Kontext erfordern. KI-Regulierung wird als Kompetenzfeld gefasst, das EU AI Act, DSGVO und urheberrechtliche Fragen umfasst (Gimpel et al., 2024, S. 12). Juristische Kompetenz wird als eigenständige Kategorie operationalisiert (Lorenz et al., 2025); Fraunhofer FIT (2025) betont insbesondere die rechtliche Einordnung von Datenschutz, Urheberrecht und EU AI Act als zentral für Implementierung. Bitkom e.V. (2025a, S. 46) unterstreichen

die Notwendigkeit kontinuierlicher Auseinandersetzung mit der Kombination aus Datenschutz-, Urheber- und Haftungsfragen.

REFLEXION DER ERGEBNISSE UND FORSCHUNGSLÜCKEN

Die Literatur zeigt ein breites Kompetenzspektrum für produktiven und verantwortungsvollen GenAI-Einsatz. Demgegenüber legen empirische Befunde eine ausgeprägte Kompetenzlücke in deutschen Unternehmen nahe, die sich durch technische Integrationskomplexität, unterschätzte Transformationsanforderungen sowie unzureichende Weiterbildung und strategische Verankerung erklären lässt.

Gleichzeitig bleibt eine zentrale Forschungslücke: Zwar existieren Stellenanzeigenanalysen zu KI-Kompetenzen, die sowohl Trends als auch inhaltliche Anforderungen adressieren (Büchel et al., 2025a, 2025b; Büchel & Mertens, 2022; OECD, 2024a, 2024b; Rampelt, Klier, et al., 2025). Diese fokussieren jedoch häufig KI-Kompetenzen in der Breite bzw. allgemeine Anwenderkompetenzen und adressieren Expertenrollen nur begrenzt. Mackensen et al. (2024, S. 4f.) analysieren zwar gezielt KI-Expertenstellen im deutschen Arbeitsmarkt, jedoch ohne spezifischen GenAI-Fokus. Offen bleibt damit, welche GenAI-Kompetenzen Unternehmen für Expertenstellen tatsächlich nachfragen – obwohl gerade dieser Bereich das stärkste Nachfragewachstum aufweist (Büchel & Engler, 2025, S. 2). Zudem fehlt bislang ein systematischer Abgleich arbeitsmarktlicher Kompetenznachfrage mit einem theoriegeleiteten Kompetenzrahmen, um Übereinstimmungen und Lücken zwischen Forschung und Praxis sichtbar zu machen. Diese Arbeit adressiert diese Lücke; das methodische Vorgehen wird im folgenden Kapitel dargestellt.

Methodik


Um die in deutschen Stellenanzeigen formulierten Kompetenzanforderungen im Kontext generativer KI systematisch erfassen zu können, wurde eine strukturierende qualitative Inhaltsanalyse nach Mayring (2022) durchgeführt. Ziel ist es, GenAI-Kompetenzanforderungen in deutschsprachigen Stellenanzeigen für den deutschen Arbeitsmarkt zu identifizieren und diese mit den abgeleiteten theoretischen Kompetenzprofilen abzugleichen. Stellenanzeigen eignen sich hierzu, weil sie Kompetenzanforderungen sowohl explizit (z. B. durch konkrete Tool- oder Programmiersprachennennungen) als auch implizit (z. B. durch Aufgabenbeschreibungen wie Integration von RAG-Workflows) operationalisieren und damit reale arbeitsmarktseitige Nachfrage abbilden.

Methodisch folgt die Untersuchung einem deduktiv-induktiven Vorgehen nach Kuckartz und Rädiker (2024). Im ersten Schritt werden die zwölf, theoriegeleitet hergeleiteten Kompetenzfelder (K1–K12) deduktiv auf das Datenmaterial angewendet. Im zweiten Schritt werden ergänzend Anforderungen extrahiert, die außerhalb des Kategoriensystems liegen, um emergente Kompetenzfelder zu identifizieren.

Die Analyse wird KI-gestützt mithilfe eines Large Language Models (LLM) umgesetzt (Abb. 1) und orientiert sich am überwachten Ablaufmodell der KI-basierten Inhaltsanalyse nach Fischer (2025). Damit wird der Anspruch verbunden, dass Kodierlogik, Prompt-Design und Qualitätssicherung nachvollziehbar und reproduzierbar dokumentiert sind. Die Gestaltung strukturierter Prompts orientierte sich ergänzend an dokumentierten Best-Practice-Empfehlungen für die Arbeit mit

Claude-Modellen (Anthropic, o. J.). Studien zeigen, dass LLM-gestützte deduktive Kodierung substantielle Übereinstimmung mit menschlicher Kodierung erreichen kann (Chew et al., 2023; Tai et al., 2024). Für den deutschen Kontext der Auswertung von KI-Stellenanzeigen liegen zudem Vorarbeiten vor, die die grundsätzliche Eignung solcher Verfahren demonstrieren (Mackensen et al., 2024).

Abb. 1: Überblick Methodik



Quelle: Eigene Darstellung

In allen Analyseschritten wurde konsistent Claude Haiku 4.5 (Anthropic; Modellkennung: claude-haiku-4-5-20251001) eingesetzt. Die einheitliche Modellwahl dient der methodischen Konsistenz, da die Analyseschritte überwiegend regelgeleitete Klassifikationsentscheidungen auf Basis eines Codebuchs darstellen.

DATENERHEBUNG UND DATENAUFBEREITUNG

Als Datenquelle dient die Jobbörse der Bundesagentur für Arbeit (BA). Die Erhebung erfolgte über eine öffentlich erreichbare REST-Schnittstelle der BA-Jobsuche, deren technische Struktur über die Dokumentation von bund.dev nachvollziehbar ist (bund.dev, o. J.), und wurde am 14. März 2026 durchgeführt. Sie umfasste alle zu diesem Zeitpunkt aktiv geschalteten Arbeitsstellen.

Die Suche wurde mit neun GenAI-spezifischen Suchbegriffen durchgeführt, die deutsche und englische Fachterminologie abdecken: Generative AI, Generative KI, Large Language Model, LLM, Prompt Engineering, RAG, Foundation Model, Sprachmodell, Generative Künstliche Intelligenz.

Breite Suchbegriffe wie „KI“ oder „Machine Learning“ wurden bewusst ausgeschlossen, um klassische KI-Stellen ohne konkreten GenAI-Bezug nicht systematisch in die Stichprobe zu vermischen. Insgesamt wurden auf diese Weise 506 Rohanzeigen erfasst.

Die Rohdaten wurden in drei Schritten bereinigt:

1. Volltextfilter: Anzeigen mit weniger als 200 Zeichen im Volltext wurden ausgeschlossen, da sie in der Regel keinen verwertbaren Beschreibungstext enthalten, sondern lediglich Platzhalter oder Verweise auf externe Webseiten.
2. Duplikatsbereinigung: Duplikate wurden zweistufig entfernt:

- a. technische Duplikate anhand eindeutiger Anzeigenkennungen sowie
- b. inhaltliche Duplikate anhand identischer Kombinationen aus Stellentitel und Arbeitgeber. Falls mehrere inhaltliche Duplikate vorlagen, wurde jeweils die Anzeige mit dem neuesten Veröffentlichungsdatum beibehalten.

Nach diesen Schritten verblieben 476 bereinigte Anzeigen.

3. Inhaltliche Relevanzprüfung (GenAI-Bezug): Da Suchbegriffe auch Anzeigen erfassen können, in denen generative KI nur beiläufig erwähnt wird, wurde ein KI-gestützter Relevanzfilter eingesetzt. Eine Anzeige wurde als relevant klassifiziert, wenn generative KI ein konkreter Bestandteil der Aufgaben oder Anforderungen ist (z. B. Entwicklung, Implementierung, Integration, Steuerung, Governance oder strategischer Einsatz von LLM/RAG/Foundation-Model-Systemen). Der Relevanzfilter ist damit bewusst so gewählt, dass er primär Stellen erfasst, in denen GenAI-Kompetenzen im Sinne professioneller Implementierung, Integration, Betrieb oder Governance gefordert werden. Reine Anwender- bzw. Nutzungsszenarien (z. B. „Nutzung von ChatGPT im Arbeitsalltag“ ohne Implementierungs-/Verantwortungsbezug) wurden konsequent ausgeschlossen. Eine Anzeige wurde als nicht relevant klassifiziert, wenn

- a. GenAI nur als gelegentliches Nutzertool erwähnt wird,
- b. ausschließlich klassisches Machine Learning/Data Science ohne Sprachmodellbezug beschrieben wird oder
- c. GenAI nur in einem Satz ohne konkreten Stellenbezug auftaucht.

Die Relevanzprüfung erfolgte mit Claude Haiku 4.5, deterministisch mit temperature=0 und einer strikt binären Ausgabe (JA/NEIN). Zusätzlich wurde max_tokens=5 gesetzt, um die maximale Antwortlänge technisch stark zu begrenzen. Hierdurch wurde das Risiko reduziert, dass das Modell erläuternden Fließtext ausgibt; zugleich erhöht dies die Formatstabilität und senkt die Kosten der Prüfung.

Von den 476 bereinigten Anzeigen wurden 258 als relevant eingestuft (54,2%); 218 Anzeigen (45,8%) wurden ausgeschlossen.

DATENAUSWERTUNG UND KODIERUNG

Zur deskriptiven Charakterisierung der Stichprobe wurden Arbeitsort und Veröffentlichungsdatum ausgewertet. Da das Feld Arbeitsort in der BA-Datenstruktur als dict-ähnlicher String vorliegt, wurden daraus Stadt und Bundesland extrahiert; fehlende Einträge wurden als „Remote / k. A.“ klassifiziert. Zusätzlich wurde die Anzeigedauer in Tagen bis zum Erhebungsdatum (14. März 2026) berechnet und der Veröffentlichungsmonat bestimmt.

Ergänzend wurden die Stellentitel regelbasiert in vier Senioritätsstufen klassifiziert: Junior/Einstieg, Mid-Level/Nicht spezifiziert, Senior/Spezialist und Leadership/Manager. Die Zuordnung erfolgte über eine Schlüsselwortliste (u. a. junior, trainee, werkstudent; senior, expert, principal; lead, head of, manager). Die Regelreihenfolge ist bewusst gewählt (z. B. Prüfung „Junior“ vor „Senior“), um Überschneidungen konsistent zu behandeln.

Das Kategoriensystem wurde vollständig deduktiv aus der vorherigen Literaturanalyse abgeleitet und umfasst die zwölf definierten Kompetenzfelder K1 Datenkompetenz & Data Science, K2

Programmierung, K3 IT-Infrastruktur, Cloud & MLOps, K4 Modellentwicklung & Fine-Tuning, K5 Prompt Engineering, K6 KI-Strategie & Use-Case-Identifikation, K7 Prozessintegration & Systemdenken, K8 Change-Management & Führung, K9 Agiles Projekt- & Innovationsmanagement, K10 Kritische Reflexion & Output-Bewertung, K11 KI-Governance & Ethik und K12 Juristische Kompetenzen & Compliance. Für jede Kategorie wurde ein Codebuch erstellt, das eine operationale Definition, typische Ankerbegriffe/Beispiele und Kodierregeln (Mayring, 2022) enthält. Die Kodierung wurde binär realisiert (1 = Kompetenz explizit oder eindeutig erkennbar gefordert, 0 = Kompetenz nicht erkennbar oder nur vage angedeutet). Zur Vermeidung von Überinterpretation galt eine konservative Regel: Im Zweifel wurde 0 vergeben. Die 258 relevanten Anzeigen wurden mit Claude Haiku 4.5 deduktiv kodiert. Zur Sicherstellung maschinenlesbarer Ergebnisse wurden strukturierte Ausgaben erzwungen: Das Modell musste ein valides JSON-Objekt liefern, das ausschließlich die Felder K1–K12 mit den Werten 0 oder 1 enthält.

Weiterführend wurde zur Identifikation typischer Anforderungsbündel auf Stellenebene auf Basis der binären Kompetenzprofile (K1–K12) eine K-Means-Clusteranalyse durchgeführt. Da die Clusteranzahl bei K-Means nicht a priori feststeht, wurde sie explorativ mittels Elbow-Methode bestimmt. Hierzu wurde für $k=2$ bis $k=10$ die Inertia berechnet, d.h. die Summe der quadrierten Abstände der Datenpunkte zu ihren jeweiligen Clusterzentren. Der „Knick“ (Elbow) im Inertia-Verlauf wurde bei $k=3$ beobachtet; daher wurde $k=3$ als pragmatische, datengetriebene Clusteranzahl gewählt.

Die Clusteranalyse ist explorativ zu verstehen und dient der Identifikation gut interpretierbarer Kompetenzbündel auf Stellenebene. Obwohl K-Means klassisch auf euklidischen Distanzen basiert und damit nicht speziell für binäre Variablen entwickelt wurde, ist das Verfahren hier als pragmatischer Verdichtungsschritt geeignet, da die Kompetenzprofile (K1–K12) als niedrigdimensionale Merkmalsvektoren vorliegen und die Interpretation der Clusterzentren unmittelbar als „typische Profile“ möglich ist. Alternative Clusterverfahren für binäre Daten (z.B. k-modes oder hierarchische Verfahren auf Basis der Jaccard-Distanz) werden als sinnvolle Robustheitsprüfung für Anschlussforschung diskutiert.

Zur Identifikation emergenter Kompetenzanforderungen außerhalb des Kategoriensystems wurde pro Anzeige eine induktive Themenextraktion durchgeführt. Das Modell wurde angewiesen, maximal drei Themenfelder zu nennen, die nicht durch K1–K12 abgedeckt sind. Um Überschneidungen zu minimieren, wurde dem Modell eine detaillierte Negativliste bereitgestellt, die die durch K1–K12 bereits abgedeckten Konzepte und typische Begriffe enumeriert. Für die explorative Themenfindung wurde $\text{temperature}=0.3$ genutzt. Die Ausgabe erfolgte strukturiert (Liste von Themenstrings).

Die extrahierten Themen wurden anschließend in zwei Schritten verdichtet:

1. regelbasierte Filterung über eine Ausschlussliste für Themen, die bei näherer Betrachtung doch in K1–K12 fallen oder zu stark nischig/branchenspezifisch sind;
2. semantische Vektorisierung der verbleibenden Themen mittels Sentence Transformers (all-MiniLM-L6-v2) und anschließende K-Means-Clusteranalyse (explorativ mit $n_clusters=8$, $random_state=42$, $n_init=10$) auf Basis normalisierter Embeddings (Kosinusähnlichkeit).

Die resultierenden Cluster wurden manuell geprüft und inhaltlich benannt; als redundant zu K1–K12 bewertete Cluster wurden verworfen.

Ergänzend wurde eine Frequenzanalyse durchgeführt, um häufig genannte Technologien, Tools und Konzepte in den Anzeigen sichtbar zu machen; unabhängig von der Kodierung. Die Frequenz- und Kontextanalysen wurden ergänzend zur deduktiven und induktiven Auswertung durchgeführt und dienen der Beschreibung explizit genannter Technologien und Begriffe im Korpus. Dazu wurden Volltexte bereinigt (Kleinschreibung, HTML-Entfernung, Sonderzeichenfilter), tokenisiert und um deutsche und englische Stoppwörter sowie stellenanzeigenspezifische Floskeln und Benefit-Begriffe bereinigt; Tokens < 4 Zeichen wurden ausgeschlossen. Auf dieser Basis wurden die häufigsten Einzelbegriffe und Bigramme ermittelt. Zusätzlich wurde eine kuratierte Frequenzanalyse vordefinierter Begriffskataloge (z. B. Programmiersprachen, Frameworks, DevOps-Tools, GenAI-Modelle, GenAI-Konzepte, Management-/Strategiebegriffe, Governance-/Rechtsbegriffe) regelbasiert durchgeführt. Gezählt wurde binär pro Anzeige (Mehrfachnennungen innerhalb einer Anzeige werden nicht mehrfach gezählt).

QUALITÄTSSICHERUNG UND LIMITATIONEN

Da die Kodierung KI-gestützt erfolgte, wurde anstelle klassischer Inter-coder-Reliabilität eine Prompt-Stabilitätsanalyse durchgeführt. Hierzu wurde eine Zufallsstichprobe von 39 Anzeigen gezogen, was 15,1% der relevanten Gesamtstichprobe ($n=258$) entspricht. Durch die Festlegung eines `random_state` wird diese Zufallsstichprobe deterministisch reproduzierbar: Bei erneuter Ausführung wird dieselbe Teilmenge der Anzeigen ausgewählt. Dies erhöht die Nachvollziehbarkeit der Reliabilitätsprüfung. Die Stichprobe wurde mit einem inhaltlich äquivalenten, aber anders formulierten Prompt erneut kodiert. Die Übereinstimmung zwischen Erst- und Zweitkodierung wurde je Kategorie sowie insgesamt mittels Cohen's κ berechnet und nach Landis und Koch (1977) interpretiert. Der Gesamtwert beträgt $\kappa = 0,874$ („almost perfect agreement“). Die niedrigsten Werte entfallen auf K10 ($\kappa = 0,694$) und K12 ($\kappa = 0,787$), was auf eine höhere Interpretationsoffenheit reflexiver bzw. compliancebezogener Kategorien hindeutet.

Bei der (folgenden) Interpretation der Ergebnisse sind folgende Limitationen zu berücksichtigen:

1. Die Datenbasis umfasst ausschließlich die BA-Jobbörse; andere Plattformen (z. B. LinkedIn, StepStone) sind nicht enthalten.
2. Die Erhebung bildet eine Momentaufnahme (14. März 2026) in einem dynamischen Feld.
3. Das binäre Kodierformat erfasst das Vorhandensein, nicht jedoch Intensität oder Priorisierung von Kompetenzen innerhalb einer Stelle.
4. Die verwendete REST-Schnittstelle ist nicht offiziell als Forschungs-API dokumentiert; zudem wurde im Abrufskript die SSL-Verifikation aus technischen Gründen deaktiviert, was als Einschränkung der technischen Integritätsabsicherung transparent zu machen ist.
5. Teile der Pipeline behandeln Abruf- bzw. Kodierfehler tolerant; dies reduziert Abbrüche, kann jedoch im Ausnahmefall zu stillen Ausfällen einzelner Datensätze führen.

Ergebnisse und Diskussion

STICHPROBE UND DATENBASIS

Die empirische Analyse basiert auf 258 deutschsprachigen Stellenanzeigen für den deutschen Arbeitsmarkt, die am 14. März 2026 über die Jobbörse der Bundesagentur für Arbeit erhoben und nach

einem GenAI-Relevanzfilter ausgewählt wurden. Die Anzeigen bilden damit eine Momentaufnahme des Arbeitsmarkts für GenAI-bezogene Rollen zum Erhebungszeitpunkt.

Hinsichtlich der Anzeigedauer, also der Zeitspanne zwischen Veröffentlichungsdatum und Erhebungsdatum, ergibt sich ein Median von 25,5 Tagen. Die Hälfte der Stellen war damit weniger als vier Wochen aktiv geschaltet, was auf eine hohe Aktualität der Stichprobe hinweist. Gleichzeitig waren rund 22 Prozent der Anzeigen bereits länger als 90 Tage online. Dies kann als Indikator für eine erschwerte Besetzbarkeit interpretiert werden, wenngleich aus Anzeigendauer allein keine eindeutige kausale Schlussfolgerung zulässig ist (z. B. können auch interne Freigabeprozesse oder wiederholtes Re-Posting eine Rolle spielen).

Die Senioritätsverteilung zeigt, dass knapp die Hälfte der Anzeigen keiner eindeutigen Erfahrungsstufe zuzuordnen ist und als Mid-Level bzw. nicht spezifiziert klassifiziert wurde (49,2%, n=127). Diese Gruppe umfasst Stellen, deren Titel keine expliziten Marker wie „Junior“, „Senior“ oder „Manager“ enthalten; plausibel ist jedoch, dass es sich überwiegend um Positionen oberhalb des Einstiegsniveaus handelt. Der zweitgrößte Anteil entfällt auf Senior- und Spezialistenstellen (27,1%, n=70). Junior- und Einstiegsstellen sind mit 14,7% (n=38) vergleichsweise selten, Leadership- und Managementpositionen stellen mit 8,9% (n=23) die kleinste Gruppe. Insgesamt deutet dies auf einen weiterhin stark erfahrungsgetriebenen Markt hin, in dem GenAI-Kompetenzen vor allem in Rollen mit höherer Verantwortung und/oder spezialisierten Profilen nachgefragt werden.


Geografisch zeigt sich eine deutliche Konzentration in wirtschaftsstarken Regionen. Bayern ist mit 67 Anzeigen (26,0%) am stärksten vertreten, gefolgt von Nordrhein-Westfalen (44; 17,1%) und Baden-Württemberg (35; 13,6%). Damit entfallen mehr als 50% der Anzeigen auf diese drei Bundesländer. Ostdeutsche Bundesländer sind nur vereinzelt vertreten (z. B. Sachsen mit 12 Anzeigen), während Sachsen-Anhalt, Brandenburg oder Mecklenburg-Vorpommern nahezu nicht vertreten sind. Zusätzlich waren 14 Anzeigen ohne konkreten Arbeitsort ausgeschrieben, was auf remote oder nicht spezifizierte Arbeitsverhältnisse hindeutet. Die regionale Verteilung entspricht damit bekannten Mustern des deutschen Technologiearbeitsmarkts. Ein erster Eindruck der sprachlichen Oberflächenstruktur ergibt sich aus den häufigsten Bigrammen. Dominant sind Machine Learning (152 Nennungen), Data Science (99), Künstliche Intelligenz (78) und Prompt Engineering (64). Bereits diese Verteilung macht deutlich, dass GenAI-Stellenanzeigen häufig in einem breiteren KI-Framing formuliert sind (z. B. „Machine Learning“), zugleich aber spezifische GenAI-Begriffe (z. B. Prompt Engineering) sichtbar werden. Dieser Befund ist für die Interpretation nachfolgender Kategorien wichtig, da er darauf hindeutet, dass Stellenanzeigen GenAI nicht immer als vollständig eigenständige Domäne sprachlich abgrenzen, sondern häufig an bestehende KI-Narrative anschließen.

KOMPETENZNACHFRAGE K1–K12: BEFUNDE UND EINORDNUNG

Zur Beantwortung der Unterforschungsfragen zur empirischen Bestandsaufnahme und zur Einordnung in das literaturbasierte Kompetenzprofil werden die 258 Stellenanzeigen entlang der zwölf Kompetenzkategorien K1–K12 kodiert. Der folgende Abschnitt beschreibt zunächst, welche Kompetenzfelder im Arbeitsmarkt sichtbar nachgefragt werden (UF1), und ordnet die Muster anschließend im Verhältnis zu den in der Literatur abgeleiteten Anforderungen ein (UF3).

Die deduktive Kodierung der 258 Anzeigen entlang der zwölf Kompetenzkategorien K1–K12 zeigt ein konsistentes Muster: Technologisch-operative Kompetenzen dominieren die Anforderungsprofile, wie in Abbildung 2 erkennbar ist.

Abb. 2: Häufigkeit der Kompetenzkategorien in GenAI-Stellenanzeigen (Eigene Darstellung)




Programmierung (K2) und IT-Infrastruktur, Cloud & MLOps (K3) sind mit jeweils 68,2% die meistgenannten Kategorien der gesamten Analyse. Modellentwicklung & Fine-Tuning (K4) folgt mit 57,4%, Datenkompetenz & Data Science (K1) mit 52,7%. Damit werden alle vier Entwicklungskategorien in mehr als der Hälfte der Anzeigen explizit gefordert, was den stark technisch geprägten Charakter des GenAI-Arbeitsmarkts unterstreicht. Diese Dominanz ist theoretisch gut anschlussfähig. Datenkompetenz wird in der Literatur als zentrale Voraussetzung produktiven KI-Einsatzes beschrieben (André & Bauer, 2021, S. 18; Di Vinadio et al., 2022, S. 60); Programmierung bildet die operative Grundlage zur Entwicklung und Integration (Baumgartner et al., 2023, S. 4).

Bemerkenswert ist zugleich, dass Prompt Engineering (K5) innerhalb des technischen Bereichs mit 38,4% deutlich hinter K1–K4 zurückbleibt. Obwohl Prompting in vielen Frameworks als GenAI-spezifische Kernkompetenz aufgeführt wird (Annapureddy et al., 2025, S. 9; Zhang & Magerko, 2025, S. 5), scheint es in Stellenanzeigen deutlich seltener als eigenständige Kompetenz formuliert zu werden. Eine plausible Erklärung liegt darin, dass Prompting in stark technischen Rollen als impliziter Bestandteil der Entwicklungstätigkeit verstanden und daher nicht explizit ausgeschrieben wird. Dass Prompting dennoch arbeitsmarktrelevant ist, zeigen sowohl die Begriffsebene (Prompt Engineering als häufiges Bigramm) als auch die Rollenprofile (vgl. Abschnitt 5.3). Dies entspricht dem Befund, dass Prompting-Kenntnisse häufig als Zusatzanforderung in bestehenden Rollen nachgefragt werden, ohne dass sich ein eigenständiger Berufstitel in der Breite etabliert (Engler, 2025, S. 3).

Die kategorienbasierte Kodierung wurde durch eine ergänzende Frequenzanalyse konkreter Technologien, Werkzeuge und Konzepte unterstützt. Sie macht sichtbar, welche Tools und Methoden in den Stellenanzeigen explizit genannt werden, und ergänzt damit die Kompetenzkategorien um eine technologisch-sprachliche Perspektive. Bei den Programmiersprachen, dargestellt in Abbildung 3,

dominiert Python mit deutlichem Abstand: 53,1% aller Anzeigen nennen die Programmiersprache explizit. Der Abstand zwischen Python und allen anderen Programmiersprachen ist bemerkenswert groß, denn SQL folgt erst mit 13,6% auf dem zweiten Platz. TypeScript, Java und JavaScript werden jeweils in rund 10% der Anzeigen genannt, gefolgt von R und Go mit jeweils rund 9%. Sprachen wie PHP (3,5%), C++ (3,1%) oder Rust (0,8%) spielen hingegen eine untergeordnete Rolle. Insgesamt bestätigt diese Tool-Perspektive den in der Literatur beschriebenen Status von Python als Standardsprache in KI-nahen Entwicklungsrollen (vgl. Annapureddy et al., 2025, S. 10) und stützt damit die hohe Bedeutung der Kategorien K2 und K3 auf der Kompetenzebene.

Abb. 3: Häufigkeit – Programmiersprachen




Die Frequenzanalyse der ML- und KI-Frameworks ergänzt dieses Bild und deutet auf eine starke Praxisorientierung der Nachfrage hin. LangChain führt mit 17,4% die Rangliste an, gefolgt von PyTorch (15,1%) und TensorFlow (12,4%). Auffällig ist, dass LangChain als speziell auf LLM-Anwendungen ausgerichtetes Framework die beiden etablierten Deep-Learning-Bibliotheken übertrifft. Scikit-learn folgt mit 7,8%, FastAPI mit 4,7%; weitere Tools (u. a. LlamaIndex, Databricks, Pandas) werden jeweils in knapp 4% genannt. Insgesamt zeigt sich damit eine breite Streuung über viele Tools, wobei keines der Frameworks in mehr als einem Fünftel der Anzeigen explizit gefordert wird. Im Zusammenspiel mit den hohen Werten für K2–K4 spricht dies dafür, dass Unternehmen weniger nach „einem dominanten Stack“ suchen, sondern nach generalisierbarer Implementierungsfähigkeit, die sich auf unterschiedliche Toollandschaften übertragen lässt.

Die Analyse der GenAI-Konzepte und Methoden (Abb. 4) zeigt eine klare Hierarchie mit zwei dominierenden Begriffen: LLM wird in 34,1% der Anzeigen explizit genannt, RAG in 31,8%. Prompt Engineering folgt mit 22,1%, Retrieval mit 13,2%. Agentic AI ist mit 6,2% bereits in einem nennenswerten Anteil vertreten, während Fine-Tuning und Diffusion jeweils 3,1% erreichen; Multi-Agent und Embedding jeweils 1,9%. Die Begriffslandschaft korrespondiert damit nur teilweise mit der Kompetenzkodierung: Während RAG und LLM sprachlich prominent sind, werden verwandte Kompetenzen (z. B. Modellentwicklung/Fine-Tuning) häufiger kodiert als ihre expliziten Begriffsnennungen vermuten lassen. Dies unterstreicht, dass Unternehmen Anforderungen häufig über

Aufgabenformulierungen operationalisieren, ohne die zugrundeliegenden Konzepte immer als Schlagworte zu benennen.

Abb. 4: Häufigkeit – GenAI-Konzepte & Methoden



Im Bereich Management & Strategie fällt Prozessintegration & Systemdenken (K7) mit 61,2% besonders auf. K7 ist damit nicht nur die stärkste Managementkategorie, sondern die zweithäufigste Kategorie des gesamten Datensatzes. Der Befund ist theoretisch konsistent: Prozess- und Systemkompetenz wird in der Literatur als Schlüssel zur produktiven Integration generativer KI in Wertschöpfungsprozesse beschrieben (Ehlers et al., 2023, S. 235; Weinberg, 2025, S. 9; Kupi et al., 2025, S. 20). Auf Begriffsebene stützt sich diese Interpretation dadurch, dass Transformations- und Strategiebegriffe zwar sichtbar sind, aber insgesamt deutlich seltener explizit genannt werden als technische Terminologie (z. B. Transformation 19,8% vs. Strategie 10,5%; Enablement/Stakeholder jeweils ca. 6%). Dies legt nahe, dass Managementanforderungen in Stellenanzeigen eher selektiv und häufig implizit adressiert werden.

KI-Strategie & Use-Case-Identifikation (K6) sowie Agiles Projekt- und Innovationsmanagement (K9) werden jeweils in rund 40% der Anzeigen gefordert und liegen damit auf einem ähnlichen Niveau wie K5. Change-Management & Führung (K8) ist hingegen mit 15,1% die seltenste Kategorie im Managementbereich. Dieses Ergebnis steht in einem Spannungsverhältnis zu vielen Kompetenzrahmen, die Change-Kompetenzen als zentral für KI-Transformationen hervorheben (Neuhaus et al., 2024, S. 481; Baumgartner et al., 2023, S. 4f.; Kirchherr et al., 2025, S. 5). Zwei Interpretationen sind möglich: (1) Change-Kompetenzen werden als implizite Führungsfähigkeit vorausgesetzt und daher nicht explizit formuliert. (2) Unternehmen unterschätzen weiterhin die nicht-technische Einführungscomplexität und externalisieren die „menschliche Dimension“ (z. B. an HR, interne Kommunikation oder externe Beratung), wodurch sie in den hier betrachteten GenAI-Stellenanzeigen weniger sichtbar wird (Hughes et al., 2026, S. 1f.). Dass Change-Management auch als Begriff nur selten explizit genannt wird (2,7%), stützt eher die erste Interpretation einer geringen expliziten Artikulation als die Annahme einer umfassenden Verankerung in der Stellenkommunikation.

Der Bereich Reflexion, Ethik & Recht weist durchgehend die niedrigsten Häufigkeiten auf. Kritische Reflexion & Output-Bewertung (K10) erreicht 31,8%, KI-Governance & Ethik (K11) 20,2%, Juristische Kompetenzen & Compliance (K12) 10,5%. Diese Verteilung bleibt auch auf Bereichsebene stabil: Der durchschnittliche Erfüllungsgrad beträgt für Technologie & Entwicklung 57,0%, für Management & Strategie 39,9% und für Reflexion, Ethik & Recht 20,8%. Damit werden reflexive, ethische und rechtliche Kompetenzen in Stellenanzeigen deutlich seltener explizit adressiert als technologische und prozessuale Kompetenzen.

Aus theoretischer Perspektive ist gerade dies auffällig. Reflexion und Output-Bewertung gelten in vielen Frameworks als nahezu universelle Kompetenz (Gimpel et al., 2024, S. 11; Greiner et al., 2024, S. 118); Governance und Compliance werden ebenfalls breit gefordert (Kupi et al., 2025, S. 24; Lorenz et al., 2025). Besonders kritisch erscheint dies vor dem regulatorischen Hintergrund: Artikel 4 des EU AI Acts verpflichtet seit Februar 2025 zur Sicherstellung ausreichender KI-Kompetenz im Personal (EU AI Act, 2024, Article 4). Gleichzeitig wird der EU AI Act in den Anzeigen nur in 1,6% explizit genannt; DSGVO erscheint in 2,3%. Die ergänzende Begriffsanalyse zeigt zwar, dass „Compliance“ (16,3%) häufiger vorkommt als spezifische Normen, jedoch bleiben Governance (7,4%), Datenschutz (5,8%) sowie Audit/Transparenz ($\leq 4,7\%$) insgesamt niedrig. Eine alternative Erklärung ist, dass rechtliche Anforderungen in separaten Rechts-/Datenschutzfunktionen gebündelt werden und damit mit anderen Suchbegriffen bzw. auf anderen Plattformen sichtbar wären. Aus Sicht dieser Arbeit ist jedoch zentral, dass governance- und compliancebezogene Anforderungen in GenAI-nahen Stellenanzeigen selten explizit formuliert werden – und damit potenziell auch seltener als Kompetenzkriterium in Recruitingprozessen wirken.

ABGLEICH MIT DEM LITERATURBASIERTEM KOMPETENZPROFIL (UF3)

Der Vergleich der Stellenanzeigenbefunde mit dem in Abschnitt „KI-Kompetenzanforderungen in der Literatur“ hergeleiteten Kompetenzprofil zeigt insgesamt eine partielle Übereinstimmung, jedoch mit systematischen Akzentverschiebungen. Übereinstimmung wird im Folgenden als arbeitsmarktseitige Sichtbarkeit von Kompetenzfeldern verstanden, die in mehreren der herangezogenen Frameworks als zentral bzw. wiederkehrend ausgewiesen werden; Abweichungen und Leerstellen beziehen sich entsprechend auf Felder, die literaturseitig stark betont, in Stellenanzeigen jedoch nur selten explizit gefordert werden. Hohe Übereinstimmung besteht insbesondere in den technologisch-operativen Kompetenzfeldern (K1–K4): Daten-, Entwicklungs- und Betriebsfähigkeit werden sowohl in der Literatur als auch im Arbeitsmarkt als zentrale Voraussetzung professioneller GenAI-Implementierung adressiert. Ebenfalls konsistent ist die hohe Sichtbarkeit von Prozessintegration und Systemdenken (K7), die in Kompetenzrahmen als Schlüsselkompetenz zur produktiven Einbettung von KI in Wertschöpfungsprozesse hervorgehoben wird.

Demgegenüber treten Abweichungen dort auf, wo Kompetenzrahmen GenAI-spezifische Schnittstellen- und Transformationskompetenzen stärker betonen, diese in Stellenanzeigen jedoch seltener explizit als Anforderung erscheinen. Dies betrifft erstens Prompt Engineering (K5), das in der Literatur häufig als Kernkompetenz generativer Systeme ausgewiesen wird, in den Anzeigen jedoch deutlich hinter den klassischen Entwicklungs- und Betriebsanforderungen zurückbleibt. Zweitens zeigt sich ein Spannungsverhältnis bei Change-Management & Führung (K8): Während entsprechende


Kompetenzen in der Literatur als zentral für Adoption und Skalierung beschrieben werden, bleiben sie in der Stellenkommunikation vergleichsweise unsichtbar.

Als besonders relevante Leerstelle ist schließlich die geringe Explizitheit reflexiver, ethischer und rechtlicher Anforderungen (K10–K12) zu bewerten. Obwohl Output-Bewertung, Governance und Compliance in der Literatur breit adressiert werden, werden diese Kompetenzfelder arbeitsmarktseitig deutlich seltener ausgeschrieben. Vor dem Hintergrund regulatorischer Anforderungen (u. a. EU AI Act, Art. 4) deutet dies auf eine potenzielle Diskrepanz zwischen normativ-institutionellen Erwartungen und der operativen Artikulation von Kompetenzkriterien im Recruiting hin.

ROLLEN- UND KOMPETENZPROFILE: KO-VORKOMMEN UND CLUSTERBILDUNGEN

Aufbauend auf der Häufigkeitsanalyse wird im nächsten Schritt untersucht, welche Kompetenzen typischerweise gemeinsam auftreten und welche wiederkehrenden Kompetenzbündel sich auf Stellenebene identifizieren lassen (UF2). Ziel ist es, aus den Einzelkategorien typische Rollen- bzw. Anforderungsprofile abzuleiten, die über reine Rangfolgen hinausgehen.

Abb. 5: Gemeinsames Auftreten von Kompetenzkategorien (eigene Darstellung)




Die Analyse des gemeinsamen Auftretens von Kompetenzkategorien (Abb. 5) zeigt, welche Kompetenzen typischerweise gemeinsam nachgefragt werden. Innerhalb des technischen Kompetenzblocks sind die Ko-Vorkommen besonders hoch: Programmierung (K2) und IT-Infrastruktur/MLOps (K3) treten in 57% aller Anzeigen gemeinsam auf. Ähnlich ausgeprägt sind die Kombinationen K2+K4 (50%) und K3+K4 (48%). Auch K1 tritt häufig gemeinsam mit K2 (42%) und K4 (43%) auf. Insgesamt entsteht damit ein eng gekoppelter technischer Kern, der einen Großteil technischer Rollenanforderungen strukturiert.

Prozessintegration & Systemdenken (K7) nimmt eine Brückenfunktion ein. K7 ko-okkurriert sowohl mit strategischen Kategorien (K6 und K9 jeweils 38%) als auch mit technischen Kategorien (K3: 41%; K2: 36%). K7 ist damit die Kategorie mit den breitesten Verbindungen über Bereichsgrenzen hinweg und

operationalisiert die Schnittstelle zwischen technologischer Implementierung und organisationaler Einbettung.

Die Ko-Vorkommen zwischen Technologie & Entwicklung und Reflexion/Ethik/Recht sind hingegen überwiegend gering (meist < 20%). K8 überschreitet in keiner Kombination 15%, K12 in keiner 10%. Diese Muster stützen die Interpretation, dass Governance-, Rechts- und Change-Kompetenzen in der Stellenkommunikation deutlich seltener als integrale Bestandteile technischer GenAI-Rollen erscheinen.

Abb. 6: Kompetenzcluster im Vergleich (eigene Darstellung)



Zur Identifikation typischer Kompetenzbündel auf Stellenebene wurde zusätzlich eine K-Means-Clusteranalyse durchgeführt, aus welcher sich folgende drei Rollentypen ergaben:

- **Rollentyp A (n=105) zeigt ein ausgeprägt technisches Profil**
K2 liegt bei 95%, K3 bei 85%, K4 bei 75%, K1 bei 62%. Strategische Kategorien sind nahezu absent (K6: 3%; K8: 1%). Dieser Rollentyp entspricht primär GenAI-Engineering-/Implementierungsrollen, in denen technische Tiefe dominiert.
- **Rollentyp B (n=71) weist ein anwendungs- und prozessorientiertes Profil auf**
Technische Kategorien sind deutlich schwächer vertreten (K2: 18%; K3: 17%; K4: 7%), während Prozessintegration (K7: 76%), Prompt Engineering (K5: 70%), Projektmanagement (K9: 54%) und Strategie (K6: 45%) dominieren. Auch K10 ist mit 46% deutlich stärker vertreten als in Rollentyp A. Der Befund stützt die Interpretation, dass Prompt Engineering in der Praxis weniger mit klassischer Modellentwicklung, sondern stärker mit anwendungsnaher Orchestrierung, Prozessintegration und Governance-naher Output-Verantwortung verknüpft ist.
- **Rollentyp C (n=82) bildet ein hybrides Profil mit hoher technischer und strategischer Ausprägung**

Technisch erreichen K3 91%, K4 78%, K2 77%, K1 72%; strategisch liegen K7 bei 100%, K6 bei 82% und K9 bei 76%. Rollentyp C bündelt damit technische Implementierungsfähigkeit und strategisch-prozessuale Steuerung und entspricht hybriden Rollen, wie sie auch rollenbasierte Frameworks für „AI Leaders“ bzw. „AI Professionals“ beschreiben (The Alan Turing Institute et al., 2026).

Die Überdeckungen der einzelnen Cluster, welche auch gleichzeitig die Differenzierungen zwischen ihnen darstellen, sind Abbildung 6 zu entnehmen. Ein bereichsübergreifendes Muster ist in allen drei Clustern sind allerdings konsistent: K8 (Change-Management & Führung) und K12 (Juristische Kompetenzen & Compliance) erreichen in keinem Rollentyp Mittelwerte oberhalb von 30%. Damit bestätigt die Clusterperspektive die bereits in der Häufigkeitsanalyse sichtbare Marginalisierung dieser beiden Kompetenzfelder in der Stellenkommunikation.

Die Rollentypen legen nahe, dass Kompetenzanforderungen systematisch nach Seniorität variieren (z. B. mehr K6/K11/K12 in Leadership-Rollen). In der vorliegenden Auswertung wurde Seniorität bislang deskriptiv erfasst, aber nicht als Subgruppenvergleich analysiert. Eine nachgelagerte Auswertung der K-Profile nach Senioritätsstufen könnte die Rollenlogik weiter präzisieren und die Ableitung zielgruppenspezifischer Weiterbildungsprogramme stärken.

EMERGENTE KOMPETENZFELDER AUßERHALB VON K1–K12

Ergänzend zur deduktiven Kodierung (K1–K12) wurden induktiv weitere, in den Stellenanzeigen wiederkehrende Anforderungsdimensionen identifiziert, um mögliche Praxisanforderungen abzubilden, die in bestehenden Kompetenzrahmen bislang nur begrenzt operationalisiert sind (Ergänzung zu UF1/UF3).

Die induktive Analyse identifizierte fünf emergente Kompetenzfelder, die außerhalb des deduktiven Kategoriensystems liegen. Die Häufigkeiten liegen insgesamt unterhalb vieler deduktiver Kategorien, was darauf hindeutet, dass der Großteil arbeitsmarktseitiger Anforderungen durch K1–K12 abgedeckt ist. Gleichwohl treten einzelne Felder mit einer Häufigkeit auf, die sie als eigenständige Anforderungsdimensionen ausweist. Aus der induktiven Verdichtung wurden die folgenden fünf Bereiche abgeleitet:

1. KI-Didaktik und Wissensvermittlung,
2. branchenspezifisches Domänenwissen,
3. KI-Tool-Evaluierung,
4. UX/UI und Human-Centered Design sowie
5. MCP und KI-Protokolle,

welche im Folgenden im Detail definiert werden:

Das am häufigsten genannte Feld sind Anforderungen im Bereich der **KI-Didaktik und Wissensvermittlung** (19,8%; n=51). Dieser Bereich umfasst Anforderungen an die Konzeption und Durchführung von Schulungen, den Aufbau von Lernpfaden sowie Enablement-Formate zur Befähigung von Mitarbeitenden. In der Praxis deutet dies auf eine Institutionalisierung von Lern- und Enablement-Funktionen im KI-Kontext hin und ist anschlussfähig an die Literatur zur strategischen Rolle von HR und Weiterbildung (Kirchherr et al., 2025, S. 5; André & Bauer, 2021, S. 10). Methodisch ist

zu berücksichtigen, dass die Datenquelle auch Anzeigen aus dem akademischen Umfeld enthalten kann, bei denen Wissensvermittlung zum Kernprofil gehört; gleichwohl bleibt die Häufigkeit als arbeitsmarktnahes Signal bedeutsam.

Branchenspezifisches Domänenwissen (15,5%; n=40) verweist auf eine in vielen generischen Kompetenzrahmen unterrepräsentierte Dimension: Unternehmen suchen nicht nur GenAI-Generalisten, sondern Fachkräfte, die KI-Systeme im jeweiligen Domänenkontext bewerten, adaptieren und verantworten können. Dies ist anschlussfähig an „Fachkompetenz“ als eigenständige Kompetenzart, wie sie etwa im AWIKI-Rahmen verankert ist (Lorenz et al., 2025).

Tool-Evaluierung (12,0%; n=31) adressiert die Fähigkeit, das wachsende Angebot an GenAI-Tools systematisch zu vergleichen und für konkrete Use Cases auszuwählen. Dieser Bereich ist, ebenso wie UX/UI & Human-Centered Design in der Literatur bisher nur begrenzt explizit operationalisiert.

UX/UI und Human-Centered Design (12,0%; n=31) verweist auf die nutzerzentrierte Gestaltung KI-gestützter Anwendungen und Schnittstellen als Akzeptanz- und Produktivitätsfaktor. Beide Felder deuten darauf hin, dass GenAI-Einführung zunehmend als Produkt- und Adoptionsthema verstanden wird, nicht nur als Modell- oder Infrastrukturfrage.

Das kleinste Feld **MCP & KI-Protokolle** (4,7%; n=12) ist aufgrund seiner Neuartigkeit bemerkenswert. Es verweist auf standardisierte Integrations- und Kommunikationsmechanismen zwischen KI-Systemen und externen Werkzeugen, wie sie etwa im Model Context Protocol beschrieben werden (Model Context Protocol, o. J.). Das dieses Feld bereits in rund jeder zwanzigsten Anzeige erscheint, zeigt die hohe Dynamik des Feldes und die zeitliche Verzögerung, mit der Kompetenzrahmen die Praxis abbilden.

Ein eigenständiger Beitrag der Analyse liegt damit in der Verbindung eines theoriegeleiteten Kompetenzrahmens mit arbeitsmarktlichen Anforderungsdaten. Die Befunde zeigen nicht nur, welche der literaturbasierten Kompetenzfelder in Stellenanzeigen sichtbar werden, sondern verdichten die beobachteten Anforderungen zugleich zu drei interpretierbaren Rollentypen: einem technischen Engineering-Profil, einem anwendungs- und prozessorientierten Profil sowie einem hybriden Profil. Darüber hinaus identifiziert die induktive Analyse fünf ergänzende Kompetenzfelder, darunter KI-Didaktik und Wissensvermittlung sowie MCP und KI-Protokolle. Diese Felder verweisen auf Praxisanforderungen, die in etablierten Kompetenzrahmen bislang nur begrenzt als eigenständige Dimensionen operationalisiert sind und daher Ansatzpunkte für deren Weiterentwicklung bieten.

IMPLIKATIONEN FÜR RECRUITING UND WEITERBILDUNG

Aus dem empirischen Befundmuster und dem Abgleich mit dem literaturbasierten Kompetenzprofil ergeben sich konkrete Implikationen für Recruiting und betriebliche Weiterbildung (UF4). Im Fokus stehen dabei (a) die kompetenzbasierte Schärfung von Rollenprofilen sowie (b) die Priorisierung von Qualifizierungsmaßnahmen unter Berücksichtigung von Governance- und Compliance-Anforderungen.

Aus den Befunden lassen sich mehrere Implikationen ableiten, die Recruiting und Weiterbildung gemeinsam adressieren, da beide in der Praxis eng verzahnt sind.

Rollenprofile kompetenzbasiert definieren

Die Clusteranalyse zeigt drei distinkte Rollentypen mit deutlich unterschiedlichen Kompetenzstrukturen. Unternehmen sollten Anforderungsprofile daher weniger über Jobtitel, sondern über konkrete Kompetenzbündel formulieren und explizit kommunizieren, ob eine Stelle einem

- a. technischen Engineering-Profil,
- b. einem anwendungs-/prozessorientierten Profil oder einem
- c. hybriden Profil entspricht.

Dies erhöht die Passgenauigkeit im Recruiting und ermöglicht zugleich eine klarere Ableitung interner Upskilling-Bedarfe (André & Bauer, 2021, S. 10; Kirchherr et al., 2025, S. 13f.).

Die folgende Tabelle 3 übersetzt die empirisch identifizierten Rollentypen in eine anwendungsorientierte Recruiting- und Weiterbildungslogik. Die Zuordnung ist nicht als starres Rollenmodell zu verstehen, sondern als heuristische Orientierung für die kompetenzbasierte Ausgestaltung von Stellenprofilen, Auswahlverfahren und Qualifizierungsprogrammen. Sie verdeutlicht zugleich, dass empirisch selten sichtbare Kompetenzfelder wie Change-Management, Governance und Compliance nicht als nachrangig interpretiert werden sollten, sondern gerade aufgrund ihrer regulatorischen und organisationalen Bedeutung systematisch in Rollenprofile und Weiterbildungsarchitekturen zu integrieren sind.

Tab. 3: GenAI Kompetenzübersicht (Eigene Darstellung)

Rollentyp	Charakteristik	Prioritäre Kompetenzfelder	Recruiting-Fokus
A: Technisches Engineering-Profil	Starke Ausprägung in Programmierung, Infrastruktur/MLOps, Modellentwicklung und Datenkompetenz; strategische und changebezogene Anforderungen treten demgegenüber nur begrenzt hervor.	K1, K2, K3, K4; ergänzend K10–K12	Anschlussfähig an Rollen wie GenAI Engineers, ML Engineers, AI Developers, MLOps Engineers oder GenAI Solution Developers
B: Anwendungs- und prozessorientiertes Profil	Fokus auf Prozessintegration, Prompt Engineering, Projektmanagement, Use-Case-Entwicklung und Output-Verantwortung; technische Tiefe ist weniger stark ausgeprägt.	K5, K6, K7, K9, K10; ergänzend K11/K12	Anschlussfähig an Rollen wie AI Consultants, AI Product Owner, Process Analysts, Business Analysts sowie Enablement- und Transformationsrollen
C: Hybrides Profil	Verbindung technischer Implementierungsfähigkeit mit strategischer und prozessualer Steuerung; hohe Relevanz für Schnittstellen zwischen Technologie, Organisation und Wertschöpfung.	K1–K4, K6, K7, K9; ergänzend K8, K11, K12	Anschlussfähig an Rollen wie AI Leads, GenAI Solution Architects, AI Transformation Manager, Senior AI Professionals oder technische Product-/Platform-Owner

Governance-, Reflexions- und Rechtskompetenzen strukturell verankern

Die geringe Sichtbarkeit von K11/K12 in Stellenanzeigen ist vor dem Hintergrund regulatorischer Anforderungen und operativer Risiken problematisch. Auch wenn rechtliche Zuständigkeiten teilweise in separaten Funktionen liegen mögen, spricht die geringe explizite Nachfrage dafür, dass diese Kompetenzen im Recruitingprozess häufig nicht systematisch geprüft werden. Unternehmen sollten

deshalb mindestens für Rollenprofile a und c governance- und compliancebezogene Anforderungen explizit machen und in Weiterbildungsprogrammen als Pflichtbestandteil verankern (EU AI Act, 2024, Article 4; Bitkom e. V., 2025a, S. 83; Greiner et al., 2024, S. 118).

Weiterbildung entlang der Rollentypen differenzieren

Rollentyp A erfordert vertiefte technische Inhalte (z. B. MLOps-Betrieb, RAG-Architekturen, Fine-Tuning) sowie flankierend Reflexions- und Compliance-Sensibilisierung. Rollentyp B benötigt v. a. Prozessanalyse, strukturiertes Prompting sowie Output-Validierung und regulatorische Grundlagen. Rollentyp C verlangt integrierte Programme, die technische und strategische Kompetenz verbinden und Change-Kompetenzen gezielt adressieren. Der niedrige Wert von K8 in den Anzeigen sollte nicht als geringe Relevanz missverstanden werden, sondern als Hinweis, dass Change-Kompetenz häufig nicht explizit ausgeschrieben wird, aber für Adoption und Governance zentral bleibt (Neuhaus et al., 2024, S. 481; Nettesheim, 2025, S. 64).

KI-Didaktik als eigenständige Funktion berücksichtigen

Das emergente Feld KI-Didaktik und Wissensvermittlung deutet auf einen wachsenden Bedarf an internen Enablement-Rollen hin. Unternehmen sollten prüfen, ob KI-Coaches, Lernpfad-Design oder Communities of Practice als dauerhafte Struktur sinnvoll sind, um Kompetenzaufbau skalierbar zu organisieren (Kirchherr et al., 2025, S. 5).

LIMITATIONEN UND WEITERER FORSCHUNGSBEDARF

Die Ergebnisse sind im Lichte mehrerer Einschränkungen zu interpretieren. Erstens basiert die Stichprobe ausschließlich auf Anzeigen der BA-Jobbörse; andere Plattformen (z. B. LinkedIn, StepStone) können andere Rollenprofile und Kompetenzsignale enthalten. Zweitens handelt es sich um eine Momentaufnahme (14. März 2026) in einem schnelllebigen Feld. Drittens erfasst die binäre Kodierung, ob eine Kompetenz erkennbar gefordert wird, nicht jedoch deren Intensität oder Priorisierung innerhalb einer Stelle. Viertens ist die Sichtbarkeit von Governance- und Rechtsanforderungen in Stellenanzeigen grundsätzlich begrenzt, da Unternehmen entsprechende Zuständigkeiten teilweise in separaten Funktionen bündeln; dies kann die niedrigen Werte für K11/K12 mit erklären. Fünftens ist die Clusteranalyse als exploratives Verfahren zu interpretieren; zukünftige Arbeiten sollten die Stabilität der Rollenprofile mit alternativen Distanzmaßen und Clustering-Algorithmen für binäre Daten prüfen.

Für Anschlussforschung ergeben sich insbesondere drei naheliegende Erweiterungen:

1. Subgruppenanalysen der Kompetenzprofile nach Seniorität (Junior/Mid/Senior/Leadership) sowie nach Region bzw. Remote-Anteilen, um differenzierte Recruiting- und Weiterbildungslogiken empirisch zu stützen.
2. Eine Plattformtriangulation (BA vs. kommerzielle Plattformen) zur Prüfung von Sampling-Effekten.
3. Eine vertiefte Operationalisierung von Governance/Compliance-Signalen (z. B. indirekte Formulierungen, Policy-Hinweise), um die Diskrepanz zwischen regulatorischer Pflicht und arbeitsmarktseitiger Artikulation präziser zu erklären.

Zusammenfassung

Zur Beantwortung der übergeordneten Forschungsfrage:

Wie manifestieren sich GenAI-Kompetenzanforderungen in deutschen Stellenausschreibungen, wie verhalten sie sich zu den in der Literatur beschriebenen Kompetenzanforderungen und welche Implikationen ergeben sich daraus für Recruiting und betriebliche Weiterbildung in Unternehmen?

wurde eine KI-gestützte qualitative Inhaltsanalyse von 258 relevanten Stellenanzeigen (BA-Jobbörse, Stichtag 14. März 2026) durchgeführt.

Die Anzeigen wurden entlang eines deduktiv-induktiv entwickelten Kategoriensystems mit zwölf Kompetenzfeldern (K1–K12) kodiert, durch Ko-Vorkommens- und Clusteranalysen zu Rollenprofilen verdichtet und um Frequenzanalysen explizit genannter Technologien und GenAI-Konzepte ergänzt.

Die Leitfrage wird durch vier Unterforschungsfragen konkretisiert:

1. Welche GenAI-bezogenen Kompetenzen werden in deutschen Stellenausschreibungen gefordert?
2. Welche typischen Kompetenzbündel bzw. Stellenprofile lassen sich identifizieren?
3. Inwiefern stimmen die empirischen Anforderungen mit dem literaturbasierten Kompetenzprofil überein und wo zeigen sich Abweichungen oder Leerstellen?
4. Welche Handlungsempfehlungen ergeben sich daraus für Recruiting und Weiterbildung?

Zu UF1 zeigt sich eine ausgeprägte Technologielastigkeit des GenAI-Stellenmarkts: Programmierung (K2) und IT-Infrastruktur/Cloud/MLOps (K3) werden jeweils in 68,2% der Anzeigen gefordert; Modellentwicklung & Fine-Tuning (K4) in 57,4% und Datenkompetenz & Data Science (K1) in 52,7%. Der Kompetenzbereich Technologie & Entwicklung weist damit den höchsten Erfüllungsgrad auf (57,0%). Die Frequenzanalyse konkretisiert dies: Python dominiert als Programmiersprache (53,1%); LangChain (17,4%) wird häufiger genannt als PyTorch (15,1%) und TensorFlow (12,4%). Auf Konzept-Ebene treten LLM (34,1%) und RAG (31,8%) als zentrale Bezugspunkte hervor.

Zu UF2 zeigt die Verdichtung auf Stellenebene drei wiederkehrende Rollenprofile: (A) ein technischer Engineering-Typ, (B) ein anwendungs- und prozessorientierter Typ sowie (C) ein hybrider Typ, der technische Tiefe mit strategischer Prozessintegration verbindet. Die hybriden Profile erscheinen besonders wertschöpfungsrelevant, da sie die Brücke zwischen Implementierung und organisationaler Einbettung schlagen.

Zu UF3 ist die Dominanz technischer Kompetenzen grundsätzlich anschlussfähig an die Literatur, die Daten-, Entwicklungs- und Betriebsfähigkeit als Grundlage produktiven KI-Einsatzes beschreibt. Gleichzeitig werden nicht-technische Transformations- sowie reflexive und normative Anforderungen in Stellenanzeigen deutlich seltener explizit artikuliert: Change-Management & Führung (K8) wird nur in 15,1% genannt; Kritische Reflexion & Output-Bewertung (K10) erreicht 31,8%, KI-Governance & Ethik (K11) 20,2% und Juristische Kompetenzen & Compliance (K12) 10,5%. Diese Unterrepräsentation ist insbesondere vor dem Hintergrund des EU AI Acts (Art. 4) bemerkenswert, zumal der EU AI Act in den Anzeigen nur selten explizit erwähnt wird. Dies kann darauf hindeuten, dass Compliance-Kompetenzen organisatorisch ausgelagert oder im Recruiting nicht systematisch sichtbar gemacht werden; in beiden

Fällen besteht das Risiko einer unzureichenden Verankerung von Governance- und Prüfkompetenzen im operativen GenAI-Einsatz.

Ergänzend identifiziert die induktive Analyse fünf emergente Kompetenzfelder, die in etablierten Frameworks bislang nur begrenzt systematisch abgebildet sind: KI-Didaktik & Wissensvermittlung, branchenspezifisches Domänenwissen, KI-Tool-Evaluierung, UX/UI & Human-Centered Design sowie MCP & KI-Protokolle. Insbesondere die häufige Nennung von KI-Didaktik deutet auf eine zunehmende Institutionalisierung von Enablement- und Lernfunktionen im KI-Kontext hin.

Aus UF4 folgen Implikationen für die Unternehmenspraxis: GenAI-Einführung ist weder ein reines Tool- noch ein reines IT-Projekt. Unternehmen sollten Rollenprofile kompetenzbasiert entlang der identifizierten Rollentypen definieren, Weiterbildungsarchitekturen rollenspezifisch differenzieren und Governance-, Reflexions- sowie Compliance-Kompetenzen systematisch und sichtbar verankern – unabhängig davon, ob diese in Stellenanzeigen aktuell explizit gefordert werden. Die zwölf Kompetenzfelder (K1–K12) und die drei Rollenprofile bieten hierfür eine strukturierte Grundlage zur Diagnose von Kompetenzlücken und zur Ausrichtung von Recruiting- und Upskilling-Maßnahmen.

Einschränkend ist zu berücksichtigen, dass die Ergebnisse auf einer Momentaufnahme der BA-Jobbörse beruhen, die Auswahl über GenAI-Suchbegriffe erfolgte und die binäre Kodierung die Sichtbarkeit, nicht aber die Gewichtung einzelner Anforderungen erfasst. Anschlussforschung sollte daher Subgruppenanalysen (z. B. nach Seniorität), Plattformtriangulation sowie eine differenziertere Erfassung der Priorisierung von Kompetenzen ergänzen.

Literaturverzeichnis

- Adebayo, K. S. (2025, April 25). *The AI skills gap is slowing down supply chains*. Forbes.
<https://www.forbes.com/sites/kolawolesamueladebayo/2025/04/25/the-ai-skills-gap-is-slowing-down-supply-chains/>
- Ahuja, K. A. (2024). *Skills-based hiring guidance and competency model for artificial intelligence work*. U.S. Office of Personnel Management. <https://www.opm.gov/chcoc/transmittals/2024/Skills-Based%20Hiring%20Guidance%20and%20Competency%20Model%20for%20Artificial%20Intelligence%20Work.pdf>
- André, E., & Bauer, W. (2021). *Kompetenzentwicklung für Künstliche Intelligenz: Veränderungen, Bedarfe und Handlungsoptionen*. https://doi.org/10.48669/pls_20212
- Annapureddy, R., Fornaroli, A., & Gatica-Perez, D. (2025). Generative AI literacy: Twelve defining competencies. *Digital Government: Research and Practice*, 6(1). <https://doi.org/10.1145/3685680>
- Anthropic. (o. J.). *Best practices für Prompting*. Claude API Docs. Abgerufen am 13. März 2026, von <https://platform.claude.com/docs/de/build-with-claude/prompt-engineering/claude-prompting-best-practices>
- Armutat, S., Wattenberg, M., Mauritz, N., & Franken, S. (2025). Generative AI competencies – Framework and maturity model for users in their work settings. *International Conference on AI Research*, 22–29. <https://doi.org/10.34190/icaire.5.1.4371>
- Baumgartner, M., Horvat, D., & Kinkel, S. (2023). *Künstliche Intelligenz in der Arbeitswelt – Eine Analyse der Kompetenzbedarfe auf Unternehmensebene*. 69. Kongress der Gesellschaft für Arbeitswissenschaft e. V., Hannover. <https://kompetenzzentrum-karl.de/wp-content/uploads/2023/09/Baumgartner-Horvat-et-al.-2023-Kuenstliche-Intelligenz-in-der-Arbeitswelt.pdf>
- Bendel, O. (o. J.). *Generative KI*. Gabler Wirtschaftslexikon. Abgerufen am 27. Dezember 2025, von <https://wirtschaftslexikon.gabler.de/definition/generative-ki-124952>
- Bitkom e. V. (2025a). *Generative KI im Unternehmen: Rechtliche Fragen zum Einsatz generativer Künstlicher Intelligenz im Unternehmen*. <https://www.bitkom.org/Bitkom/Publikationen/Generative-KI-im-Unternehmen>
- Bitkom e. V. (2025b, September 15). *Durchbruch bei Künstlicher Intelligenz*. <https://www.bitkom.org/Presse/Presseinformation/Durchbruch-Kuenstliche-Intelligenz>
- Bitkom e. V. (2026). *Umsetzungsleitfaden zur KI-Verordnung: Compliance in der Praxis – Schritt für Schritt* (Version 2.0). <https://www.bitkom.org/Bitkom/Publikationen/Umsetzungsleitfaden-zur-KI-Verordnung>
- Brynjolfsson, E., Li, D., & Raymond, L. (2025). Generative AI at work. *The Quarterly Journal of Economics*, 140(2), 889–942. <https://doi.org/10.1093/qje/qjae044>

- Büchel, J., & Engler, J. F. (2025). *Generative KI: Ein Wachstumstrend*. IW-Kurzbericht, 38.
<https://www.iwkoeln.de/studien/jan-buechel-jan-felix-engler-ein-wachstumstrend.html>
- Büchel, J., & Mertens, A. (2022). *KI-Bedarfe in Deutschland: Regionale Analyse und Entwicklung der Anforderungsprofile in KI-Stellenanzeigen*. Institut der deutschen Wirtschaft.
<https://www.iwkoeln.de/studien/jan-buechel-armin-mertens-regionale-analyse-und-entwicklung-der-anforderungsprofile-in-ki-stellenanzeigen.html>
- Büchel, J., Engler, J. F., & Mertens, A. (2025a). *Die Suche nach KI-Fachkräften in Deutschland: Rekrutierungsstrategien in Stellenanzeigen*. Institut der deutschen Wirtschaft.
<https://www.iwkoeln.de/studien/jan-buechel-jan-felix-engler-armin-mertens-rekrutierungsstrategien-in-stellenanzeigen.html>
- Büchel, J., Engler, J. F., & Mertens, A. (2025b). *KI-Jobs in Deutschland: Stagnation statt Boom: Eine Analyse von Online-Stellenanzeigen*. Bertelsmann Stiftung. <https://doi.org/10.11586/2025025>
- bund.dev. (o. J.). *Dokumentation der REST-Schnittstelle der Bundesagentur für Arbeit*. Abgerufen am 13. März 2026, von <https://jobsuche.api.bund.dev/>
- Cedefop. (2025). *Skills empower workers in the AI revolution: First findings from Cedefop's AI skills survey*. Publications Office of the European Union. <https://doi.org/10.2801/6372704>
- Chew, R., Bollenbacher, J., Wenger, M., Speer, J., & Kim, A. (2023). *LLM-assisted content analysis: Using large language models to support deductive coding* (Version 1). arXiv.
<https://doi.org/10.48550/ARXIV.2306.14924>
- Chui, M., Durth, S., Hazan, E., Huyghues-Despointes, R., Madgavkar, A., Maor, D., Dandona, G. S., & Smit, S. (2024). *Eine neue Zukunft der Arbeit: Der Wettlauf um die Einführung von KI in Europa – Welche Fähigkeiten jetzt gefragt sind*. McKinsey Global Institute.
<https://www.mckinsey.de/~media/mckinsey/locations/europe%20and%20middle%20east/deutschland/news/presse/2024/2024%20-%2005%20-%2023%20mgi%20genai%20future%20of%20work/mgi%20report%20genai%20future%20of%20work%20deutsch.pdf>
- Daly, M., Groes, F., & Jensen, M. F. (2024). Skill demand versus skill use: Comparing job posts with individual skill use on the job. *Labour Economics*, 92, Article 102661.
<https://doi.org/10.1016/j.labeco.2024.102661>
- Deming, D., & Kahn, L. (2017). *Skill requirements across firms and labor markets: Evidence from job postings for professionals* (NBER Working Paper No. 23328). National Bureau of Economic Research. <https://doi.org/10.3386/w23328>
- Di Vinadio, T. B., van Noordt, C., del Castillo, C. V. A., Avila, R., Scanish, M. V., & Stewart, N. (2022). *Artificial intelligence and digital transformation: Competencies for civil servants*. UNESCO / ITU.
<https://unesdoc.unesco.org/ark:/48223/pf0000383325>

- DSGVO: Verordnung (EU) 2016/679 des Europäischen Parlaments und des Rates vom 27. April 2016 zum Schutz natürlicher Personen bei der Verarbeitung personenbezogener Daten, zum freien Datenverkehr und zur Aufhebung der Richtlinie 95/46/EG. (2016). <https://eur-lex.europa.eu/eli/reg/2016/679/oj/deu>
- Ehlers, U.-D., Lindner, M., Sommer, S., & Rauch, E. (2023). AICOMP – Future skills in a world increasingly shaped by AI. *Ubiquity Proceedings*, 3(1), 230–239. <https://doi.org/10.5334/uproc.91>
- Engler, J. F. (2025). *Prompt Engineer: Zwischen Hype und Realität*. IW-Kurzbericht, 57. <https://www.iwkoeln.de/studien/jan-felix-engler-zwischen-hype-und-realitaet.html>
- Erpenbeck, J., Heyse, V., Meynhardt, T., & Weinberg, J. (2021). *Die Kompetenzbiographie: Wege der Kompetenzentwicklung* (3., durchgesehene Aufl.). Waxmann.
- Ertel, W. (2025). *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung* (6. Aufl.). Springer Vieweg. <https://doi.org/10.1007/978-3-658-44955-1>
- EU AI Act: Verordnung (EU) 2024/1689 des Europäischen Parlaments und des Rates vom 13. Juni 2024 zur Festlegung harmonisierter Vorschriften für künstliche Intelligenz. (2024). <https://eur-lex.europa.eu/eli/reg/2024/1689/oj/deu>
- Europäische Kommission, Cosgrove, J., & Cachia, R. (2025). *DigComp 3.0: European digital competence framework*. Publications Office of the European Union. <https://doi.org/10.2760/0001149>
- Fischer, A. (2025). *Die Zukunft der Qualitativen Inhaltsanalyse im Zeitalter Künstlicher Intelligenz: Ein Ablaufmodell KI-basierter Inhaltsanalyse*. Forschungsinstitut Betriebliche Bildung. <https://doi.org/10.25656/01:34405>
- Fraunhofer FIT. (2025, Februar 3). *KI-Kompetenzen stärken: Fraunhofer FIT Generative AI Lab unterstützt Unternehmen bei der Erfüllung des EU AI Act Art. 4*. <https://nachrichten.idw-online.de/2025/02/03/ki-kompetenzen-staerken-fraunhofer-fit-generative-ai-lab-unterstuetzt-unternehmen-bei-der-erfuellung-des-eu-ai-act-art-4>
- Gimpel, H. (2024). *KI-Kompetenzen in der Wirtschaftsinformatik*. OSF. <https://doi.org/10.17605/OSF.IO/WBD84>
- Gimpel, H., Gutheil, N., Mayer, V., Bandtel, M., Büttgen, M., Decker, S., Eymann, T., Feulner, S., Kaya, M. F., Kufner, M., Kühl, N., Lämmermann, L., Maedche, A., Ruiner, C., Schoop, M., & Urbach, N. (2024). *(Generative) AI competencies for future-proof graduates: Inspiration for higher education institutions*. Institut für Wirtschaftsinformatik und Marketing; Zentrum für Mediales Lernen. <https://doi.org/10.5445/IR/1000168799>
- Greiner, R., Böck, M., & Rashedi, J. (2024). *Quick Guide KI-Kompetenz für Analytics: Was Sie über KI wissen müssen und wie Sie die AI-Literacy in Ihrer Organisation erhöhen*. Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-44306-1>

- Grimberg, E., & Mason, C. (2025). *Building proficiency in generative AI: Key competencies for success*. <https://doi.org/10.32388/INFMMJ.3>
- Hagedorn, S. & Linke, K. (2025). *Was der EU AI Act für Kommunen in Niedersachsen bedeutet – Risiken, Chancen und Handlungsempfehlungen*. Niedersächsischer Städtetag 53(4). S. 27-28.
- Hubel, N., Peters, R., Hille, M., & Goluchowicz, K. (2025). *Generative KI – Technologieszenarien und Auswirkungen auf Arbeit bis 2030*. Bundesministerium für Arbeit und Soziales, Denkfabrik Digitale Arbeitsgesellschaft. [https://www.denkfabrik-bmas.de/fileadmin/Downloads/Publikationen/Generative KI Technologieszenarien und Auswirkungen auf Arbeit bis 2030.pdf](https://www.denkfabrik-bmas.de/fileadmin/Downloads/Publikationen/Generative_KI_Technologieszenarien_und_Auswirkungen_auf_Arbeit_bis_2030.pdf)
- Hughes, L., Davies, F., Li, K., Gunaratne, S. M., Malik, T., & Dwivedi, Y. K. (2026). Beyond the hype: Organisational adoption of generative AI through the lens of the TOE framework – A mixed methods perspective. *International Journal of Information Management*, 86, Article 102982. <https://doi.org/10.1016/j.ijinfomgt.2025.102982>
- Kirchherr, J., Störk, K., Bérubé, V., Rupietta, K., & Senst, M. (2025). *HR-Monitor 2025: Eine umfassende Benchmark-Umfrage zu Personal- und HR-Trends in Europa liefert wertvolle Impulse für HR-Führungskräfte*. McKinsey & Company. https://www.mckinsey.com/de/~/_media/mckinsey/locations/europe%20and%20middle%20east/deutschland/news/presse/2025/2025-07-18%20hr%20monitor%202025/hr%20monitor%202025%20report%20deutsch_final.pdf
- Kissin, E. (2025, October 6). Deloitte issues refund for error-ridden Australian government report that used AI. *Financial Times*. <https://www.ft.com/content/934cc94b-32c4-497e-9718-d87d6a7835ca>
- KPMG AG. (2025). *Generative KI in der deutschen Wirtschaft 2025: Wo stehen deutsche Unternehmen bei der Implementierung generativer KI?* <https://kpmg.com/de/de/home/themen/2025/04/studie-generative-ki-in-der-deutschen-wirtschaft-2025.html>
- Kuckartz, U., & Rädiker, S. (2024). *Qualitative Inhaltsanalyse: Methoden, Praxis, Umsetzung mit Software und künstlicher Intelligenz* (6. Aufl.). Beltz Juventa.
- Kupi, M., Goldacker, G., & Wachsmann, D. (2025). *Kompetenzen für den Einsatz generativer Künstlicher Intelligenz in der Verwaltung*. Kompetenzzentrum Öffentliche IT, Fraunhofer-Institut für Offene Kommunikationssysteme FOKUS. <https://www.oeffentliche-it.de/publikationen/kompetenzen-fuer-den-einsatz-generativer-kuenstlicher-intelligenz/>
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174. <https://doi.org/10.2307/2529310>
- Laupichler, M. C., Aster, A., Haverkamp, N., & Raupach, T. (2023). Development of the “Scale for the assessment of non-experts’ AI literacy” – An exploratory factor analysis. *Computers in Human Behavior Reports*, 12, Article 100338. <https://doi.org/10.1016/j.chbr.2023.100338>

- Long, D., & Magerko, B. (2020). What is AI literacy? Competencies and design considerations. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 1–16. <https://doi.org/10.1145/3313831.3376727>
- Lorenz, A., Lorenz, R., Bauer, B., Stieler, F., & Klingel, A. (2025). *KI-Kompetenzrahmen für Organisationen: Ein praktisches Instrument zur Umsetzung der EU-KI-Verordnung*. Audit- und Wissenszentrum für vertrauenswürdige KI. [https://www.it-planungsrat.de/fileadmin/it-planungsrat/der-it-planungsrat/schwerpunktthemen/KI-Kompetenzrahmen_f%C3%BCr_Organisationen_Ein_praktisches_Instrument_zur_Umsetzung_der_EU-KI-Verordnung_Audit- und Wissenszentrum_f%C3%BCr_verantwortungsvolle_KI.pdf](https://www.it-planungsrat.de/fileadmin/it-planungsrat/der-it-planungsrat/schwerpunktthemen/KI-Kompetenzrahmen_f%C3%BCr_Organisationen_Ein_praktisches_Instrument_zur_Umsetzung_der_EU-KI-Verordnung_Audit-_und_Wissenszentrum_f%C3%BCr_verantwortungsvolle_KI.pdf)
- Mackensen, J., Ruppert, R., & Bienzeisler, B. (2024). *Qualifizierungsbedarfe und Künstliche Intelligenz – Ein webanalytischer Ansatz mittels Generativer KI*. Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO. <https://doi.org/10.24406/w-34901>
- Mayring, P. (2022). *Qualitative Inhaltsanalyse: Grundlagen und Techniken* (13., überarb. Aufl.). Beltz.
- Model Context Protocol. (o. J.). *What is the Model Context Protocol (MCP)?* Abgerufen am 19. März 2026, von <https://modelcontextprotocol.io/docs/getting-started/intro>
- Morandini, S., Fraboni, F., De Angelis, M., Puzzo, G., Giusino, D., & Pietrantoni, L. (2023). The impact of artificial intelligence on workers' skills: Upskilling and reskilling in organisations. *Informing Science: The International Journal of an Emerging Transdiscipline*, 26, 39–68. <https://doi.org/10.28945/5078>
- Myszak, J. M., & Filina-Dawidowicz, L. (2025). Leaders' competencies and skills in the era of artificial intelligence: A scoping review. *Applied Sciences*, 15(18), Article 10271. <https://doi.org/10.3390/app151810271>
- Nettesheim, K. (2025). *KI-Kompetenz: Für eine Zukunft in Wohlstand* (1. Aufl.). Verlag Franz Vahlen. <https://doi.org/10.15358/9783800675050>
- Neuhaus, U., Schulz, M., Schröder, H., & Herrmann, F. (2024). Kompetenzfelder künftiger Beschäftigter im Bereich Künstlicher Intelligenz. *HMD Praxis der Wirtschaftsinformatik*, 61(2), 471–484. <https://doi.org/10.1365/s40702-024-01046-7>
- OECD. (2024a). *OECD-Bericht zu Künstlicher Intelligenz in Deutschland*. OECD Publishing. <https://doi.org/10.1787/8fd1bd9d-de>
- OECD. (2024b). *Artificial intelligence and the changing demand for skills in the labour market* (OECD Artificial Intelligence Papers No. 14). OECD Publishing. <https://doi.org/10.1787/88684e36-en>
- Onnen, A. (2024). AI-specific skills for integration into existing competency frameworks. *E-Journal VFU*. <https://doi.org/10.2139/ssrn.5072947>
- 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>

- Rampelt, F., Klier, J., Kirchherr, J., & Ruppert, R. (2025). *KI-Kompetenzen in deutschen Unternehmen: Schlüssel zu einer Jahrhundertchance für Deutschland*. Stifterverband für die Deutsche Wissenschaft. <https://doi.org/10.5281/ZENODO.14637137>
- Rampelt, F., Matthes, W., Hannken-Illjes, K., Sandmeir, A., Gehrs, V., Horstmann, N., Kunz, A. M., Eigbrecht, L., Johannsen, T., Blum, S., Frank, S., Sutter, C., & Koch, H. (2025). *Future Skills 2030: Ein aktualisiertes Framework für Zukunftskompetenzen*. Zenodo. <https://doi.org/10.5281/ZENODO.17910748>
- Sengar, S. S., Hasan, A. B., Kumar, S., & Carroll, F. (2024). Generative artificial intelligence: A systematic review and applications. *Multimedia Tools and Applications*, 84(21), 23661–23700. <https://doi.org/10.1007/s11042-024-20016-1>
- Singla, A., Sukharevsky, A., Hall, B., Yee, L., Chui, M., & Balakrishnan, T. (2025). *The state of AI in 2025: Agents, innovation, and transformation*. McKinsey & Company. <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>
- Tai, R. H., Bentley, L. R., Xia, X., Sitt, J. M., Fankhauser, S. C., Chicas-Mosier, A. M., & Monteith, B. G. (2024). An examination of the use of large language models to aid analysis of textual data. *International Journal of Qualitative Methods*, 23. <https://doi.org/10.1177/16094069241231168>
- The Alan Turing Institute, Innovate UK, Department for Science, Innovation and Technology, Digital Catapult, Science and Technology Facilities Council, British Standards Institution, & Alliance for Data Science Professionals. (2026). *AI skills for business competency framework* (Version 3.0.0). Zenodo. <https://doi.org/10.5281/ZENODO.18892559>
- Weinberg, A. I. (2025). *A framework for the adoption and integration of generative AI in midsize organizations and enterprises (FAIGMOE)* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2510.19997>
- Wildhirt, K., Bub, U., & Vogel, M. (2025). Generative KI erfolgreich in Unternehmen implementieren. *Wirtschaftsinformatik & Management*, 17(3–4), 119–128. <https://doi.org/10.1365/s35764-025-00558-1>
- Zhang, C., & Magerko, B. (2025). *Generative AI literacy: A comprehensive framework for literacy and responsible use* (arXiv:2504.19038; Version 2). arXiv. <https://doi.org/10.48550/arXiv.2504.19038>