Erfahrungen mit KI im Technologie-Wissensmanagement

Von der manuellen Datenrecherche zur KI-gestützten Wissenssynthese

Dr.-Ing. Hans-Jürgen Boßmeyer veröffentlicht auf www.hjb-technologies.de (2026)

Abstract / Kurzfassung
Das Management technologischen Wissens steht vor einem radikalen Paradigmenwechsel. Während die strategische Einordnung von Technologien (Top-Down) und die konkrete Problemlösung im Engineering (Bottom-Up) traditionell immense personelle und zeitliche Ressourcen banden, ermöglichen moderne generative KI-Systeme eine fundamentale Beschleunigung. Dieses Paper beschreibt die methodische Evolution des Technologiemanagements von frühen datengetriebenen Automatisierungsansätzen (2021) über erste Experimente mit spezialisierten Bots und Prompt Engineering (2023) bis hin zur heutigen echten „Schreibtisch-Automatisierung“. Es wird aufgezeigt, wie der historische Ansatz standardisierter Technologiedatenblätter durch die automatisierte Attribut-Extraktion auf eine neue Stufe gehoben wird. Das Dokument selbst dient dabei als lebender Proof of Concept für die kollaborative Wissenssynthese zwischen menschlichem Experten und Large Language Models (LLMs).

1. Einleitung und Problemstellung: Das „Zehn-Studenten-Dilemma“

Die Identifikation, Strukturierung und Verknüpfung von Subtechnologien – seien es nanostrukturierte Oberflächen, moderne Leistungselektronik oder innovative Verbundwerkstoffe – war traditionell eine der ressourcenintensivsten Aufgaben im industriellen Innovationsmanagement.
Ein klassischer Rückblick verdeutlicht den radikalen Effizienzsprung der Gegenwart: Wo früher eine Projektgruppe von zehn Studierenden ein halbes Jahr lang das Internet, Fachpublikationen und Patentdatenbanken hätte durchforsten müssen, um Querverbindungen und technologische Abhängigkeiten mühsam sichtbar zu machen, gelingt diese systematische Erfassung heute mithilfe künstlicher Intelligenz in einem Bruchteil der Zeit. KI fungiert in diesem Kontext als horizontale Integrationsschicht, die unstrukturierte Datenmengen fehlerfrei scannt und verborgene Technologiemuster ad hoc sichtbar macht. Der menschliche Aufwand verschiebt sich dadurch fundamental von der zeitintensiven Fleißarbeit der Datensammlung hin zur strategischen Bewertung und kreativen Systemgestaltung.

2. Die historische Evolution:
Vom Daten-Crawler zum generativen Sparringspartner

Die Methodik, wie technologisches Wissen organisiert wird, hat in den letzten Jahren eine rasante Entwicklung durchlaufen, die sich in drei wesentlichen Phasen beschreiben lässt:

Phase 1: Das datengetriebene Fundament (2021) – TCB & SETS

Im Jahr 2021 wurde im Rahmen der Veröffentlichungsarbeiten mit Prof. Günther Schuh und André Bräkling (Data-Driven Technology Management Supported by Artificial Intelligence Solutions) das theoretische und praktische Fundament für ein modernisiertes Technologiemanagement gelegt. Im Zentrum standen die Systeme der Technologie-Chancen-Bewertung (TCB) und der Systematischen Entwicklung Technologischer Systeme (SETS). Das Ziel war es, generische Technologie-informationen von außerhalb des Unternehmens mit dem internen Technologie-wissen in einer umfassenden Datenbank zu verschmelzen (Schuh, Boßmeyer & Bräkling, 2021). Damals wurden frühe KI-Architekturen wie Focused Web Crawling und Named Entity Recognition skizziert, um die unstrukturierte Technologie-landschaft teilautomatisiert in granulare Sub-Technologieprofile zu formen. Es war ein wichtiger, aber noch stark regelbasierter und softwareseitig starrer Ansatz.

Phase 2: Der Aufbruch der LLMs und das Bot-Experiment (2023)

Mit dem Durchbruch der Large Language Models (LLMs) im Jahr 2023 verschob sich der Fokus radikal auf die direkte Interaktion zwischen Mensch und Maschine. In der Arbeit Technologische Intelligenz verbessern: Die Rolle des Prompt Engineering bei der KI-Nutzung (Oktober 2023) wurde aufgezeigt, wie durch gezielte, präzise Frageformulierungen (Prompt Engineering) die Antwortqualität der KI massiv gesteigert und der Schreib- und Rechercheallltag optimiert werden kann (Boßmeyer, 2023).

In der Folgezeit wurden in der industriellen Praxis zahlreiche spezialisierte „Subtechnologie-Bots“ erprobt. Die darauffolgenden Praxiserfahrungen waren jedoch oft ernüchternd: Diese isolierten Bots agierten meist zu starr. Sie füllten zwar vordefinierte Datenfelder, verloren dabei jedoch den globalen technologischen Kontext und waren nicht in der Lage, interdisziplinäre Querverbindungen eigenständig zu synthetisieren oder komplexe, didaktische Transferleistungen zu erbringen.

Phase 3: Die heutige Synthese (2026) – Das generative Co-Authoring

Heute erleben wir den Sprung von der reinen, isolierten Informationsextraktion zur echten konzeptionellen Zusammenarbeit. Moderne KI-Systeme wie Gemini agieren

nicht mehr als starr programmierte Bots, sondern als kontextbewusste, dynamische Sparringspartner. Diese Entwicklung hin zum generativen Co-Authoring im Jahr 2026 deckt sich mit aktuellen empirischen Metastudien (vgl. MDPI Scoping Review, 2024/2025), die eine rapide Beschleunigung bei der KI-Unterstützung im Engineering-Alltag nachweisen. LLMs agieren heute nicht mehr als isolierte Werkzeuge, sondern als tief integrierte Co-Piloten, die den Wissenstransfer in den frühen Phasen der Technologieentwicklung radikal verkürzen. Sie sind in der Lage, das gesamte historische Fundament eines Experten zu erfassen, komplexe hierarchische Muster im Dialog zu spiegeln und unstrukturierte Technologiedaten in Echtzeit in präzise Fachaufsätze zu transformieren.

3. Die Architektur des Technologiewissens: Top-Down vs. Bottom-Up

Ein ganzheitliches Technologiemanagement muss permanent zwei entgegengesetzte Bewegungsrichtungen bedienen und synchronisieren, wie es bereits in klassischen planerischen Frameworks verankert ist (Phrall, Farrukh & Probert, 2004):

- **Die Top-Down-Perspektive:** Sie geht von der strategischen Führungsebene aus. Hier werden übergeordnete Technologiebereiche (z. B. Materials oder Mobility) nach standardisierten Prozessen der Technologiefrüherkennung definiert (Schuh & Klappert, 2011) und in Technologiefamilien unterteilt, um zukünftige Kompetenzfelder des Unternehmens langfristig abzustecken.
- **Die Bottom-Up-Perspektive:** Sie repräsentiert den akuten Bedarf der Praxis. Der Ingenieur an der Front steht vor einer spezifischen physikalischen oder konstruktiven Herausforderung und benötigt dafür eine sofortige, funktionale Lösung aus dem Raum der existierenden Subtechnologien.

Der traditionelle Bottom-Up-Prozess scheiterte in der Praxis oft an der Starrheit klassischer Datenbanken. Wer als Entwickler nicht bereits im Vorfeld die exakten physikalischen Fachbegriffe oder Bezeichnungen einer fremden Disziplin kannte, blieb in seinem Fachsilo gefangen. Moderne KI-Systeme transformieren diesen Prozess radikal in eine funktionsorientierte Bottom-Up-Suche: Der Ingenieur beschreibt lediglich das technische Problem und die physikalischen Randbedingungen; die KI übersetzt diese Anforderungen eigenständig, durchbricht interdisziplinäre Grenzen und extrahiert autonom die passenden Lösungsvorschläge.

4. Der evolutionäre Sprung der Mustererkennung:
Das automatisierte Datenblatt

Ein etablierter und inhärent logischer Ansatz für eine systematische Patentlösung im Technologiemanagement basierte bisher auf der Standardisierung: Alle relevanten Subtechnologien sollten nach einem identischen, homogenen Schema in standardisierten Datenblättern erfasst werden. Durch das präzise Befüllen definierter Attribute

(z. B. thermische Grenzen, mechanische Kennwerte) sollten Gleichartigkeiten und technologische Synergien erkennbar werden (Schuh & Klappert, 2011).
Die moderne KI-Entwicklung hebt diesen Ansatz auf eine neue Stufe:

- **Die KI benötigt den Umweg über das Datenblatt nicht mehr zwingend**, um Korrelationen zu verstehen. Aufgrund ihrer Fähigkeit zur semantischen Mustererkennung kann sie unstrukturierte Texte direkt im Vektorraum miteinander verknüpfen.
- **Der Ingenieur benötigt das Datenblatt jedoch weiterhin.** Für den praktischen Entwicklungsprozess, die Validierung und den Bauteilvergleich sind verlässliche, visuell vergleichbare Kennzahlen unverzichtbar.

Die Synthese liegt in der **automatisierten Attribut-Extraktion** (Structured Information Extraction), deren tiefe algorithmische Grundlagen auf fortgeschrittenen Deep-Learning-Verfahren zur Informationsextraktion basieren (Martinez-Rodriguez et al., 2018). Der Ingenieur gibt lediglich die Subtechnologie und das gewünschte Attribut-Raster vor. Die KI durchsucht die globale Fachliteratur autonom, filtert die exakten Parameter heraus und befüllt die standardisierte Matrix in Sekunden-schnelle. Das Datenblatt wandelt sich damit von einem zeitraubenden Eingabe-werkzeug (Fleißarbeit) zu einem sofort verfügbaren Ausgabeprodukt (Expertise).

5. Das holistische Wissensökosystem: Integration von externem und proprietärem Wissen

5.1. Die Notwendigkeit der Integration von externem und internem Wissen

Eine der größten Klippen im industriellen Kontext ist die strikte Trennung von externer Marktintelligenz und internem Betriebswissen. Während der Zugriff auf globales Technologiewissen die Innovationspipeline füttert, liegt die tatsächliche Umsetzungskompetenz eines Unternehmens in seinem geschützten, internen Erfahrungsschatz begraben (historische Versuchsberichte, Prozesserfahrungen früherer Entwicklungsgenerationen). Moderne KI-Architekturen lösen dieses Dilemma durch isolierte, unternehmensspezifische Implementierungen via Retrieval-Augmented Generation (RAG) innerhalb einer geschützten Firmen-Cloud (Lewis et al., 2020).

5.2. Die Abgrenzung zu kommerziellen Trendplattformen und die Grenzen des „Bot“-Ansatzes

In der industriellen Praxis wird die Fähigkeit, internes technologisches Wissen mit externen Trends zu verknüpfen, häufig von etablierten kommerziellen Plattformen wie **ITONICS** oder **Trendone** sowie spezialisierten Scouting-Tools wie **Mapagy** oder **Mergeflow** versprochen. Diese Systeme leisten hervorragende Arbeit bei der

Aggregation, dem algorithmischen Scraping und der Visualisierung von globalen Datenströmen (Patente, Veröffentlichungen, Marktberichte).
Ihr methodischer Ansatz stößt jedoch in der Engineering-Praxis an eine systemische Grenze: Sie basieren weitgehend auf relationalen Datenbanken, vordefinierten Taxonomien oder klassischen Machine-Learning-Clustern. Der Nutzer erhält dadurch eine strukturierte, semantisch vorgefilterte Ansicht – ein „Dashboard“ der Technologielandschaft.
Das in eigenen Experimenten beobachtete Versagen einfacher Subtechnologie-Bots bei dichten Fachdaten deckt sich mit aktuellen Untersuchungen zur linguistischen Barriere bei Patenttexten (vgl. Technical Concept Study, 2025/2026). Da technische Dokumente und Patente in einer hochgradig strategischen und komprimierten Fachsprache verfasst sind, scheitern rein oberflächliche KI-Bots. Sobald ein System darauf trainiert ist, Wissen lediglich in starren Datenfeldern abzufüllen und über vordefinierte Schlagworte (Keyword-Matching) zu verknüpfen, geht die kontextuelle Tiefe verloren. Ein solcher Bot kann zwar die Frage beantworten, ob ein bestimmtes Patent oder ein spezifischer Trend existiert; er kann das darin verborgene Wissen jedoch nicht mit einer völlig fachfremden, internen Subtechnologie synergetisch und lösungsorientiert verschmelzen.

5.3. Der radikale Gegenentwurf: Kausalität vs. Wahrscheinlichkeit (Der Prisma-Analytics-Ansatz)

An dieser Bruchstelle des modernen Technologiemanagements lohnt sich der Blick auf fundamentale, alternative KI-Philosophien. Ein prägnantes Beispiel ist die von **Hardy Schloer (Prisma Analytics)** entwickelte **Quantum Relations Methode**.
Schloer formuliert eine fundamentale Kritik an heutigen Large Language Models (LLMs): Er argumentiert, dass rein generative, auf statistischen Wahrscheinlichkeiten basierende Sprachmodelle der menschlichen Logik im Kern unterlegen seien, da sie keine echten kausalen Zusammenhänge verstehen, sondern lediglich „erraten“, welches Wort als nächstes folgen müsste.
Diese fundamentale Kritik an rein probabilistischen Systemen deckt sich mit den bahnbrechenden Arbeiten von **Pearl und Mackenzie (2018)**, die nachweisen, dass rein statistische Korrelationen unfähig sind, echte Kausalität abzubilden. Ohne eine mathematisch determinierte Beziehungsebene verbleiben generative Sprachmodelle in der Rolle des reinen Sprachstatistikers, oft auch kritisch als „stochastische Papageien“ bezeichnet (**Bender & Gebru, 2021**). Der Ansatz von Prisma Analytics (Schloer 2018) setzt stattdessen auf eine strikt kausale, mathematische Abbildung der Realität. Das System zerlegt unstrukturierte Daten in fundamentale, unveränderliche Fakten und stellt die Beziehungen (Relations) dieser Fakten in einem dynamischen Netzwerk dar. Während ein LLM eine plausible, aber im

schlimmsten Fall „halluzinierte“ Verbindung zwischen zwei Subtechnologien generiert, bildet eine Quantum-Relations-Methode die unumstößliche, physikalisch-logische Kausalität einer technologischen Kette ab.

5.4. Die zukunftsweisende Synthese: Kontextuelle Vektorisierung als Brücke

Für die Schreibtisch-Automatisierung des Ingenieurs ergibt sich aus dieser Debatte eine klare technologische Synthese. Die fundamentale Kritik an rein statistischen LLMs ist berechtigt – und genau hier liegt der evolutionäre Sprung der modernen **kontextuellen Vektorisierung** via Retrieval-Augmented Generation (RAG). Die technologische Überlegenheit dieser Architektur wird durch aktuelle systematische Übersichtsarbeiten zur Dokumenten-Automatisierung aus dem Jahr 2025 gestützt (vgl. Systematic Literature Review, 2025). Sie zeigen, dass die methodische Verankerung von generativem Design mit strukturierten Vektordatenbanken das Problem der KI-Halluzinationen im industriellen Umfeld erfolgreich löst und proprietäres Wissen fehlerfrei zugänglich macht.

Eine moderne KI-Architektur liest proprietäre Dokumente heute nicht mehr als isolierte Datensätze. Sie überführt die semantischen Kernkonzepte in einen mehrdimensionalen Vektorraum. Wenn ein Industrieunternehmen einer fortgeschrittenen KI sicheren Zugang zu seinem proprietären Kernwissen gewährt, löst dies das Problem der Oberflächlichkeit auf zwei Ebenen:

1. **Semantische Brückenbildung statt reinem Keyword-Matching:**
   Sucht ein Ingenieur nach einer Lösung für ein spezifisches Vibrationsproblem im Leichtbau, durchsucht die KI das interne Wissen nicht nach dem Wort „Vibration“. Sie erfasst das zugrundeliegende physikalische Prinzip (z. B. Resonanzfrequenzen, Dämpfungsverhalten von Leichtmetalllegierungen) und spiegelt dieses in den Vektoren wider.
2. **Synthetische Kontextualisierung in Echtzeit:**
   Das System kombiniert im Moment der konkreten Anfrage das harte, interne Erfahrungswissen (z. B. „Werkstoff X neigt laut internem Versuchsbericht von 2022 bei Belastung unter 150°C zu Mikrorissen“) mit dem externen Subtechnologiewissen (z. B. den neuesten Marktdaten von Mergeflow zu Kohlenstoff-Nanoröhrchen).

Die Antwort des hochentwickelten generativen Systems ist somit keine bloße Linkliste oder ein statisches Dashboard und auch keine rein spekulative Textwüste. Es ist eine präzise, ausformulierte, kontextbezogene Synthese. Das proprietäre Wissen wird im exakten logischen Kontext der aktuellen technischen Herausforderung des Ingenieurs aktiv zum Leben erweckt.

6. Methodischer Werkstattbericht:
Die Entstehung dieses Dokuments als Proof of Concept

Dieses Paper ist nicht nur eine theoretische Abhandlung, sondern das direkte Produkt der hier beschriebenen „Schreibtisch-Automatisierung“. Die Entstehung des Dokuments im Dialog mit dem KI-System Gemini lief nach einem klar definierten, iterativen Co-Authoring-Modell ab:

1. **Kontextuelle Verankerung (Knowledge Ingestion):** Das System wurde vorab mit dem Fundament des Autors (den Publikationen aus 2021 und 2023) sowie aktuellen strukturellen Technologie-Hierarchien gefüttert (Schuh, Boßmeyer & Bräkling, 2021; Boßmeyer, 2023).
2. **Hierarchische Spiegelung (Structuring):** Im direkten Dialog wurden die logischen Muster (Top-Down/Bottom-Up) präzisiert und durchdekliniert, noch bevor Fließtext generiert wurde.
3. **Iterative Synthese (Co-Authoring):** Die KI übernahm die Rolle des Schreibwerkzeugs, das die Gedanken, Praxiserfahrungen und methodischen Konzepte des Autors in Sekundenschnelle in ein akademisch-professionelles Gewand goss.
4. **Menschliche Validierung (Human-in-the-Loop):** Die finale Kontrolle, die Einbettung der historischen Brüche und die strategische Ausrichtung verblieben vollständig in der Hand des menschlichen Experten.

Damit wird deutlich: KI ersetzt nicht den erfahrenen Technologiemanager, aber sie befreit ihn von der mechanischen Texterstellung und beschleunigt den Wissenstransfer radikal.

7. Ausblick und Fazit

7.1. Die agentenbasierte und multimodale Weiterentwicklung der KI-Unterstützung

Die Verknüpfung von menschlicher Strukturierungskompetenz und der semantischen Verarbeitungsgeschwindigkeit von KI-Systemen bricht die alten Abteilungssilos der Industrie auf. Für die Zukunft bedeutet dies, dass wertvolles Expertenwissen – auch beim Generationenwechsel im Unternehmen – nicht mehr verloren geht, sondern operativ abrufbar bleibt. Das Technologiewissen von morgen wandelt sich von einem passiven Archiv zu einem dynamischen, lernenden Gesamtsystem.

Die unmittelbare Weiterentwicklung dieser Technologie zeichnet sich durch den Übergang von rein reaktiven Chat-Assistenten hin zu **autonomen KI-Agenten** (AI Agents) aus. Während aktuelle Systeme im ständigen Dialog Schritt für Schritt Text synthetisieren, werden zukünftige Agenten-Systeme in der Lage sein, komplexe, mehrstufige Zielvorgaben autonom im Hintergrund zu bearbeiten. Ein Agent wird nach der Anweisung „Erstelle ein valides Datenblatt für die Subtechnologie X

inklusive einer Patentrecherche der letzten 24 Monate“ selbstständig externe Scouting-Werkzeuge ansteuern, Ergebnisse mathematisch via Quantum Relations validiert abgleichen, fehlende Parameter über interne RAG-Systeme ergänzen und das fertige Dokument abliefern.
Darüber hinaus wird die **Multimodalität** die zentrale Rolle einnehmen. Zukünftige KI-Unterstützung beschränkt sich nicht auf Text, sondern verknüpft technische Zeichnungen (CAD), physikalische Simulationsdiagramme und mathematische Formelwelten nahtlos miteinander, wodurch der Wissenstransfer in der industriellen Praxis eine neue Qualität erreicht.

7.2. Die kritische Effizienzfrage: Der Einfluss kommerzieller Kaufversionen

Ein zentraler Aspekt bei der Evaluierung dieses Co-Authoring-Prozesses ist die pragmatische Frage, ob der Einsatz einer kommerziellen Kaufversion (z. B. Enterprise- oder Advanced-Lizenzen) zu einem qualitativ noch hochwertigeren und präziseren Ergebnis geführt hätte.
Aus wissenschaftlicher und praktischer Sicht lässt sich diese Frage differenziert beantworten:

1. **Kontextfenster und logische Tiefe:** Kommerzielle Modelle verfügen über signifikant größere Kontextfenster. Bei der Verarbeitung extrem dichten Wissens (wie dem zeitgleichen Upload mehrerer komplexer Fachbücher und umfangreicher Patentakten) stoßen Basismodelle an Kapazitätsgrenzen. Eine Premium-Version bietet den Vorteil, noch tiefere historische Querverbindungen über hunderte von Seiten hinweg fehlerfrei im Gedächtnis zu behalten und komplexe strategische Patentsprachen feiner zu durchbrechen.
2. **API-Ökosysteme und Tool-Integration:** Der entscheidende Vorsprung kommerzieller Lizenzen liegt in der Möglichkeit, die KI über Programmierschnittstellen direkt mit spezialisierten Datenbanken (wie ITONICS, Mapagy oder internen Firmennetzwerken) zu vernetzen, anstatt Daten rein manuell zur Verfügung stellen zu müssen.
3. **Das Gesetz des abnehmenden Grenzertrags:** Gleichzeitig zeigt dieser Werkstattbericht jedoch, dass die methodische Kompetenz des Nutzers (das hierarchische Durchdeklinieren, das präzise Prompt Engineering) der entscheidende Hebel bleibt. Ein hochentwickeltes Kaufmodell liefert bei mangelhafter Führung ebenfalls nur Oberflächliches. Die Basisversion, geführt durch einen erfahrenen Experten, schlägt in der Effizienz oft eine Premium-KI ohne menschliche Strukturierungskompetenz.

Gesamtfazit: Für den alltäglichen Einstieg und die konzeptionelle Schreibtisch-Automatisierung liefert die kollaborative Interaktion mit einem modernen Basis-LLM bereits exzellente, publikationsreife Ergebnisse. Für den tiefen industriellen Einsatz, bei dem es um die fehlerfreie Verschmelzung von geschütztem Firmenwissen im Terabyte-Bereich und die kausale Absicherung von Entwicklungsschritten geht, führt der Weg in Zukunft jedoch unweigerlich über dedizierte, kommerzielle Enterprise-Modelle.

Literaturverzeichnis / Quellen

1. **Bender, E. M.; Gebru, T. (2021):** On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? Proceedings of the 2021 ACM FAccT Conference, S. 610–623.
2. **Boßmeyer, H.-J. (2023):** Technologische Intelligenz verbessern: Die Rolle des Prompt Engineering bei der KI-Nutzung. Online-Veröffentlichung auf www.hjb-technologies.de, Oktober 2023.
3. **Lewis, P. et al. (2020):** Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. Advances in Neural Information Processing Systems (NeurIPS), Vol. 33, S. 9459–94 74.
4. **MDPI Scoping Review (2024/2025):** Large Language Models in Mechanical Engineering: A Scoping Review of Applications, Challenges, and Future Directions. In: Machines / MDPI, published late 2024 / early 2025.
5. **Martinez-Rodriguez, J. L. et al. (2018):** Information Extraction using Deep Learning: A Survey. IEEE Access, Vol. 6, S. 60811–60833.
6. **Pearl, J.; Mackenzie, D. (2018):** The Book of Why: The New Science of Cause and Effect. Basic Books, New York.
7. **Phrall, R.; Farrukh, C.; Probert, D. (2004):** Technology Roadmapping: A Planning Framework for Evolution and Revolution. Research-Technology Management, Vol. 47, S. 26–36.
8. **Schloer, H. (2018):** *The Quantum Relations Principle: A Causal Predictive Paradigm for Complex Data Ecosystems*. Executive White Paper, Prisma Analytics GmbH, Munich/Singapore.
9. **Schuh, G.; Klappert, S. (Hrsg.) (2011):** Technologiemanagement Handbuch. Springer-Verlag, Berlin/Heidelberg.
10. **Schuh, G.; Boßmeyer, H.-J.; Bräkling, A. (2021):** Data-Driven Technology Management Supported by Artificial Intelligence Solutions. Journal of Production Systems and Logistics, Vol. 1, Art. 4, März 2021.
11. **Systematic Literature Review (2025):** Retrieval-Augmented Generation (RAG) and Large Language Models (LLMs) for Enterprise Knowledge

Management and Document Automation. ResearchGate / AI Review Series, mid-2025.

12. **Technical Concept Study (2025/2026):** The Missing vs. Unused Knowledge Hypothesis for Language Model Bottlenecks in Patent Understanding. Cornell University / arXiv Archive, Jan. 2026.