

KONZEPTION ERFORDERLICHER RAHMENBEDINGUNGEN FÜR DEN EINSATZ VON KÜNSTLICHER INTELLIGENZ IM UNTERNEHMEN

Jennifer Zwarg

Fakultät Wirtschafts- und Sozialwissenschaften

Hochschule Osnabrück

Caprivistraße 30a
49076 Osnabrück

E-Mail: j.zwarg@pm.me

Andreas Jede

Fakultät Wirtschafts- und Sozialwissenschaften

Hochschule Osnabrück

Caprivistraße 30a
49076 Osnabrück

E-Mail: a.jede@hs-osnabrueck.de

Frank Bensberg

Fakultät Wirtschafts- und Sozialwissenschaften

Hochschule Osnabrück

Caprivistraße 30a
49076 Osnabrück

E-Mail: f.bensberg@hs-osnabrueck.de

KEYWORDS

Systematic literature review, Artificial Intelligence, Guideline, Requirements, Company

ABSTRACT

Die Zukunftstechnologie Künstliche Intelligenz wird zunehmend in Unternehmen etabliert, um innovative Prozesse zu gestalten und nachhaltig zu optimieren. Kleine und mittlere Unternehmen nehmen KI-Einführungen nur zögerlich wahr, da diverse Ungewissheiten mit dieser Thematik verbunden sind. Ein Leitfaden soll Unternehmen eine Orientierung zu notwendigen Voraussetzungen und Handlungsbedarfen von KI-Projekten aufzeigen und Sicherheit schaffen, um weitere Unternehmen zur Realisierung zu motivieren. Eine systematische Literaturanalyse unterstützt dabei, den aktuellen Forschungsstand zu eruieren und Handlungsempfehlungen abzuleiten.

The future technology artificial intelligence is increasingly being established in companies in order to configure and sustainably improve innovative processes. Small and medium-sized businesses are hesitant to implement AI, due to various uncertainties which are associated with this subject matter. A guideline that gives companies orientation on necessary requirements and need for action in AI projects may achieve certainty and motivation to implement AI in further companies. A systematic literature review maintains to determine the current state of research and derives recommendations for action.

EINLEITUNG

Der Begriff Künstliche Intelligenz (KI) ist in der aktuellen Zeit omnipräsent und im technischen Sinne nahezu unverzichtbar. Die breite Bekanntheit dieses Trends ist insbesondere auf digitale Sprachassistenten, wie Amazon Alexa oder Google Assistant zurückzuführen. KI ist heutzutage in Smart TVs, Smartphones und Smart Watches integriert und wird als fester Bestandteil des menschlichen Alltags betrachtet. Vor allem die Bereiche autonomes Fahren und Robotik rücken zunehmend in den Vordergrund (Bolkart 2022). KI unterstützt dabei nicht nur im privaten Umfeld, sondern erzielt auch in der Industrie

Potenziale bei der Wertschöpfung in verschiedenen Anwendungsgebieten (VDMA - Verband Deutscher Maschinen- und Anlagenbau e.V. 2021).

Bei einer Umfrage von Bitkom aus dem Jahr 2020 wurden rund 600 deutsche Unternehmen ab einer Unternehmensgröße von über 20 Mitarbeitern zur Verwendung von KI befragt. Demnach sprechen sich etwa 73% der Befragten für großes Zukunftspotenzial aus. Nur etwa 6% der Unternehmen haben KI bereits im Einsatz, wohingegen 71% auch zukünftig keine Anwendung von KI planen. Ein ausschlaggebender Faktor für den Einsatz von KI wird der Größe des Unternehmens zugesprochen. Während 53% der Unternehmen mit einer Größe von 20 bis 99 Mitarbeitern KI als Potenzial für sich sehen, sind es bei einer Größe von über 2.000 Mitarbeitern bereits 84% (Streim & Uhl 2020). Ein Grund für die zögerliche Implementierung bei kleinen und mittleren Unternehmen (KMU) lässt sich auf die Komplexität von KI-Algorithmen sowie den Mangel an Fachkräften zurückführen (Deloitte Deutschland 2020). Denn 69% der Befragten geben an, dass es zu wenig KI-Fachpersonal gibt (Streim & Uhl 2020), um das vielfältige Anwendungsfeld erfolgreich in die Praxis umzusetzen.

Als neues und komplexes Forschungsfeld bringt KI für Unternehmen diverse Unsicherheiten mit sich. Vor diesem Hintergrund sollen Verantwortliche über eine Handlungsempfehlung Klarheit über notwendige Voraussetzungen im Unternehmen erhalten, die den zukünftigen Einsatz von KI ermöglichen.

Motivation und Methodik

KI ist eine vielfältig einsetzbare und komplexe Technologie, mit der Unternehmen sich einerseits wirtschaftliche Vorteile sichern können, die andererseits mit unterschiedlichen Herausforderungen behaftet ist. Bei der Einführung von KI sind verschiedene unternehmensspezifische als auch externe Faktoren zu berücksichtigen. Bereits zu Beginn eines KI-Projektes können Herausforderungen, wie die Verfügbarkeit von Fachpersonal, technische Voraussetzungen oder die Selektion eines geeigneten Algorithmus auftreten.

Vor diesem Hintergrund wird ein Konzept erarbeitet, das erforderliche Rahmenbedingungen für die erfolgreiche Implementierung einer KI-Lösung identifizieren soll.

Projektverantwortliche erhalten somit einen Überblick und erlangen Sicherheit bei der Umsetzung des zukünftigen KI-Projektes, um den erwünschten Mehrwert im Unternehmen zu generieren. Inhalt dieser Konzeption ist die Ausarbeitung der erforderlichen Rahmenbedingungen und Maßnahmen für die erfolgreiche Umsetzung eines KI-Projektes. Dabei findet eine thematische Abgrenzung zur Implementierung in die technische Infrastruktur statt, die nicht betrachtet wird. Inhaltlich werden zunächst die Grundlagen zu den Themengebieten Data Mining, KI und Maschinelles Lernen (ML) vermittelt, die im weiteren Verlauf zum Verständnis im weiteren Verlauf von Bedeutung sind.

Die systematische Literaturanalyse (SLA) dient als Forschungsmethode, mit der eine sukzessive Selektion und nachvollziehbare Auswertung der ermittelten Publikationen dargestellt wird, um relevante Voraussetzungen und Maßnahmen zu identifizieren. Die theoretischen Untersuchungsergebnisse werden in einem Modell zusammengefasst, das als Grundlage zur Anwendung in der Praxis dient. Mithilfe der theoretischen Untersuchungsergebnisse aus der SLA werden Handlungsempfehlungen abgeleitet und konzeptionell aufbereitet. Im Fazit werden die gewonnenen Erkenntnisse zusammengeführt und kritisch reflektiert.

DATA MINING UND DATA SCIENCE

Data Mining ist die Verarbeitung großer Rohdatenmengen, die aus Datenbanken extrahiert werden (Alpaydin 2022), um daraus Regeln, Muster oder Zusammenhänge zwischen verschiedenen Datensätzen zu finden (Shi & Zhu 2022). Die Begriffe Data Mining und ML werden oft miteinander in Verbindung gebracht. Dabei bestehen diese beiden Begriffe aus unterschiedlichen Konzepten (Kotu & Deshpande 2019), die im Zusammenhang mit KI im nachfolgenden Abschnitt und anhand der Abbildung 1 dargestellt werden. Während Data Mining sich u. a. auf die statistische und datenbankbezogene Anwendung konzentriert, basiert ML auf der Anwendung von Algorithmen. Generell besteht der Data Mining Prozess aus vier Schritten: Der Datenvorbereitung und -extraktion, Vorverarbeitung der Daten, der eigentlichen Durchführung des Data Mining und der Evaluation der Ergebnisse (Shi & Zhu 2022). Bereits 1996 wurde dieser Prozess von Fayyad et al. (1996) als KDD-Prozess (Knowledge Discovery in Databases) vorgestellt, auf dem viele der heutigen Modelle aufbauen. Bekannte Vorgehensmodelle sind der Cross Industry Standard Process for Data Mining (CRISP-DM) oder Analytics Solution Unified Method for Data Mining (ADUM-DM), das als Erweiterung zum CRISP-DM gilt (Brenner et al. 2021).

Mit Data Mining wird auch der Begriff Data Science in Verbindung gebracht. Dieser umfasst jedoch ein breiteres Themenspektrum als Data Mining und synthetisiert u. a. die Bereiche Statistik, Informatik, Kommunikation und Management (Cao 2017). Nach Luber & Litzel (2020) kommen im Data Science die Fachgebiete wie Data Mining, KI und ML zum Einsatz. Fachpersonal für Datenwissenschaften wird im Rahmen eines Studienganges oder durch Fortbildungen ausgebildet. Im Unternehmen

sind Data Scientists beispielsweise im Umfeld Online-Handel, Logistik und Produktion tätig (Luber & Litzel 2020).

RELEVANTE KÜNSTLICHE INTELLIGENZ

Der Begriff KI (engl. artificial intelligence, AI) lässt sich schwer abgrenzen. Bisher gibt es keine eindeutige Definition, da es sich um ein recht neues und dynamisches Forschungsgebiet handelt (Gethmann et al. 2022). Technisch betrachtet ist KI der Informatik zuzuordnen, die intelligentes Verhalten mit einem Computer simuliert (Kleesiek et al. 2020). Heutzutage gilt KI als Trend, mit dem sich viele Arten von Problemen lösen und Prozesse vereinfachen lassen. Im Forschungsumfeld ist KI beispielsweise in den Bereichen Klimaforschung, Medizin oder in der Physik etabliert (Gethmann et al. 2022).

Der Ausdruck Artificial Intelligence ist bereits 1956 durch John McCarthy, Marvin Minski, Allen Newell und Herbert Simon entstanden (Humm et al. 2022). Ein Grundstein zu intelligenten Maschinen wurde bereits 1950 durch Alan Turing (1912-1954) gelegt, der sich mit der Frage „Can machines think?“ (TURING 1950) auseinandersetzte und grundlegende Arbeiten zu Berechnungen im ‚Turing-Test‘ durchführte (Humm et al. 2022).

Ein KI-Trend fand in den USA bereits in den 60er bis 80er Jahren statt. Voreilige Schlüsse und zu optimistische Erwartungen ließen den Trend jedoch wieder abklingen. Das Wissen und die technischen Kapazitäten konnten zu dem Zeitpunkt nicht den erforderlichen Entwicklungsstand erfüllen (Humm et al. 2022). Erst mit den Sprachassistenten Siri (Apple) im Jahr 2011, gefolgt von Cortana (Microsoft) 2014 und Alexa (Amazon) 2015, nimmt KI im Alltag der Menschen wieder einen bedeutenden Aspekt ein (Robert Bosch GmbH o. J.; Wittpahl 2019). KI bietet Möglichkeiten wie Sprach- und Bilderkennung, maschinelle Übersetzungen bis hin zum autonomen Fahren. Diese Beispiele werden anhand verschiedener Teilbereiche (siehe Abbildung 1) der KI ermittelt. Aufgrund des noch recht jungen Forschungsfeldes sind diese bisher nicht einheitlich definiert (Humm et al. 2022).

KI kann in starke und schwache KI eingeordnet werden (engl. strong und weak AI). Der schwachen KI sind Anwendungen zuzuordnen, die zur Handhabung bestimmter Anwendungsfälle (AWF) konzipiert sind und mittels mathematischer und informationstechnischer Methoden das menschliche Denken unterstützen. Ohne die Zuarbeit des Menschen kann schwache KI nicht agieren. Im Gegensatz dazu soll starke KI nicht mehr auf den Menschen angewiesen sein und selbstständig wirken können. Es soll ermöglicht werden, dass sie die Intelligenz des Menschen adaptiert und ihr sogar voraus sein wird. Starke KI befindet sich derzeit noch in der Forschung (Mockenhaupt 2021).

Mit KI werden auch negative Aspekte assoziiert. In der Vergangenheit kam es zu Fehlentscheidungen der KI-Anwendungen, die zu diskriminierenden oder rassistischen Entscheidungen führten. Diese Fehlbewertungen werden Data Bias genannt und können sowohl anhand der vorliegenden Daten als auch auf die Konstruktion der

Modelle zurückzuführen sein. Jede Phase im Modellbau enthält bestimmte Praktiken und Entscheidungen, die zu einem unerwünschten Ergebnis führen können (Suresh & Guttag 2021). Eine Fehlentscheidung aufgrund von Bias kann für Unternehmen z. B. im Fall von Diskriminierung schwere wirtschaftliche Folgen und Reputationsschäden nach sich ziehen (Brenner et al. 2021).

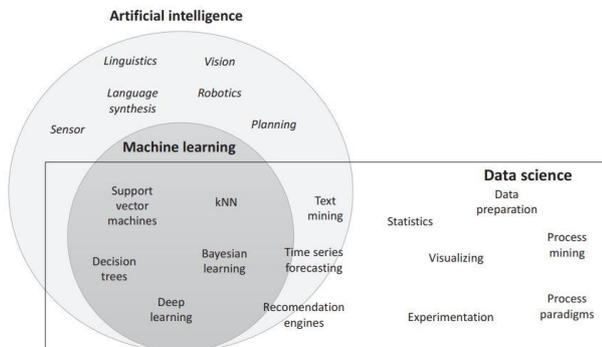


Abbildung 1: Abgrenzungen AI, ML und Data Science nach Rode-Schubert & Müller, 2020

Die Abbildung 1 verdeutlicht beispielhaft das Zusammenwirken zwischen KI, ML und Data Science. Als übergeordneter Begriff beinhaltet KI verschiedene Verfahrensmöglichkeiten. ML enthält als untergeordnete Kategorie weitere abgestimmte Verfahren, die mit den Methoden aus Data Science umgesetzt werden. Der Bereich Data Science verwendet zudem Methoden, die zur statistischen oder visuellen Auswertung angewandt werden. Durch die Abbildung 1 ist anhand der Vielzahl der einsetzbaren Algorithmen und nicht immer klaren Abgrenzung erkennbar, dass KI ein komplexes Themenfeld darstellt.

MASCHINELLES LERNEN

ML (engl. Machine Learning) ist ein Teilbereich der KI, der oft als Synonym für KI verwendet wird (Kleesiek et al. 2020; Weber 2020). Als ML wird die Fähigkeit einer Software oder Maschine bezeichnet, die mittels historischer Daten (Erfahrungen) trainiert wird (Buxmann & Schmidt 2019) und daraus Wissen generiert. Durch die Anwendung von Algorithmen wird ein komplexes Modell erstellt, mit dem das erworbene Wissen auf artgleiche Datensätze angewendet werden kann (Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V. 2018). Als Algorithmus wird dabei eine Handlungs-vorschrift bezeichnet, die schrittweise zur Lösung eines Problems beiträgt (Gethmann et al. 2022). Mit trainierten Modellen können Prognosen und Entscheidungen getroffen werden. Auswertbare Daten können Bilder, Texte oder Sensordaten sein (Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V. 2018). Modelle können prädiktiv oder deskriptiv sein. Bei prädiktiven Modellen werden anhand historischer Daten Vorhersagen (Prognosen) erstellt, während deskriptive Modelle die beobachtete Realität beschreiben (Alpaydin 2022). Mit den Methoden des ML können offene und versteckte Zusammenhänge in Datensätzen ermittelt werden (Murphy 2012). Der Fokus des ML liegt dabei auf der

kontinuierlichen Verbesserung der Lösung einer zuvor definierten Aufgabe und ist abhängig von qualitativ hochwertigen Trainingsdaten. Es werden verschiedene Arten von ML verwendet, die grob in drei Lernkategorien eingeteilt werden. Das überwachte, unüberwachte und bestärkende Lernen (Murphy 2012; Weber 2020). Diese drei Lernkategorien des ML gehören zu den gebräuchlichsten Algorithmen, die jeweils auf unterschiedlichen Lösungsansätzen basieren (Pokorni et al. 2021). Die Einstufung der Lernkategorien ist nicht abschließend geklärt, weswegen in diversen Publikationen weitere Lernkategorien zu finden sind. In den folgenden Abschnitten erfolgt eine nähere Ausführung der drei genannten Lernkategorien.

Überwachtes Lernen

Das überwachte Lernen (engl. Supervised Learning) gehört zu den mehrheitlich angewandten ML-Verfahren in der Praxis. Beim Trainieren von vorhandenen Daten wird zwischen Trainings-, Test- und Validierungsdaten unterschieden. Mit den Trainingsdaten lernt das System die Muster und Zusammenhänge. Dabei ist darauf zu achten, dass keine Überanpassung (engl. Overfitting) auftritt, da die Trainingsdaten hierbei ‚auswendig‘ gelernt werden. Das Ziel, die Trainingsdaten auf weitere Aufgaben anwenden zu können, ist im Falle einer Überanpassung nicht mehr gegeben. Das trainierte Modell wird daher zunächst zur Bewertung der Qualität auf die Testdaten angewendet und mit den zusätzlichen Validierungsdaten validiert (Mockenhaupt 2021).

Bei diesem Verfahren ist zwischen Klassifikation und Regression zu unterscheiden. Klassifikationsaufgaben haben als Output einen nominalen Wert, wie z. B. männlich oder weiblich (Murphy 2012). Ein E-Mail Spam-Filter erkennt beispielsweise eingehende E-Mails und klassifiziert sie in die Kategorien ‚Spam‘ oder ‚kein Spam‘. Anhand eines vorliegenden Datensatzes mit Informationen zu Spam und normalen E-Mails werden Merkmale bestimmt, die einer bestimmten Klasse zugeordnet werden (Weber 2020).

Die Regressionsanalyse ermöglicht Vorhersagen von stetigen, numerischen Werten. Beispielsweise kann mittels historischer Verkaufsdaten in einem Geschäft der Umsatz für die zukünftige Periode ermittelt werden (Han et al. 2011). Somit können beispielsweise prädiktive Analysen zum Umsatz eines Geschäftes anhand von zuvor definierten Produktpreisen erstellt werden (Weber 2020).

Unüberwachtes Lernen

Beim unüberwachten Lernen (engl. Unsupervised Learning) findet im Vergleich zum überwachten Lernen, keine vorherige Definition der Inputvariablen als Merkmal einer bestimmten Klasse (Han et al. 2011) oder eines bestimmten Outputs statt. Unüberwachtes Lernen dient dazu, anhand der gegebenen Inputdaten, selbstständig potenziell verborgene Muster und Strukturen zu erkennen (Murphy 2012). Beispielsweise werden Kunden aufgrund ihres Kaufverhaltens einer bestimmten Gruppe zugeordnet. Neben dem Clustering wird im unüberwachten Lernen die Assoziationsanalyse (Association Analysis)

verwendet. Dieses Verfahren kann angewendet werden, um Regeln innerhalb dieser Kundengruppenzuordnung zu identifizieren. Dabei kann z. B. anhand des historischen Kaufverhaltens ermittelt werden, in welchem Ausmaß Kunden zu einem Primärprodukt X auch ein assoziiertes Sekundärprodukt Y kaufen (Weber 2020).

Bestärkendes Lernen

Das bestärkende Lernen (engl. Reinforcement Learning) ist in der Praxis weniger verbreitet. Dieser Algorithmus basiert darauf, Verhalten mit Belohnungen oder Bestrafungen zu erlernen (Murphy 2012). Bei diesem Lernverfahren werden keine Trainingsdaten oder zuvor definierte Ergebnisse vorausgesetzt. Stattdessen müssen Regeln sowie ein Signal festgelegt werden, das die erfolgte Handlung als positiv oder negativ einstuft. Anhand der Rückmeldungen wird ein Lerneffekt erzeugt, mit dem auch bisher unbekannte Ergebnisse erreicht werden können (Mockenhaupt 2021). Mit der Häufigkeit der auftretenden Rückmeldung (positiv oder negativ) erhöht sich die Stärke und der Erkenntnisgewinn für zukünftigen Handlungen. Diese Art von Algorithmen wird z. B. bei sogenannten Agenten verwendet (Weber 2020). Mockenhaupt (2021) definiert verschiedene Arten von Agenten. Sie können beispielsweise für das Sammeln von Daten konzipiert werden oder auf ihr Umfeld einwirken. In einem Netzwerk können Agenten zum Sammeln von Daten eingesetzt werden. Dabei selektieren sie notwendige Informationen zur weiteren Übertragung und können die Auslastung regulieren (Mockenhaupt 2021).

SYSTEMATISCHE LITERATURANALYSE

Der aktuelle Forschungsstand notwendiger Voraussetzungen zur Implementierung von KI soll mit einer SLA zu mehr Handlungssicherheit führen. Mit einer gezielten Suche werden schrittweise verschiedene Forschungs- und Anwendungsergebnisse zusammengefasst und ausgewertet. Die Synthese der reduzierten Literatur wird zur Beantwortung der Forschungsfragen herangezogen.

Begriffsbestimmung und Anwendungsbereich

Die Durchführung einer SLA kann diverse Gründe haben. Einerseits bietet ein noch wenig erforschtes Thema eine geringe Anzahl theoretischer Publikationen. Zudem liegt die Herausforderung in der Strukturierung und Darstellung vorhandener Literatur (Webster & Watson 2002). Im Gegensatz zu einem jungen Forschungsfeld sind Literaturrecherchen bereits gut erforschter Themenfelder aufgrund der Masse an Publikationen zunehmend aufwändiger und unübersichtlicher geworden. Eine gezielte Suche kann dabei unterstützen, vorhandene Forschungserkenntnisse zusammenzufassen (Fettke 2006). Somit wird ein solides Grundlagenwissen über den aktuellen Forschungsstand generiert. Zudem können neue Erkenntnisse über das jeweilige Forschungsfeld erschlossen werden. Die Auswahl und Analyse relevanter Literatur ist dabei ein elementarer Bestandteil wissenschaftlicher Forschungsprojekte. Hochwertige Literaturanalysen zeichnen sich durch eine vollständige und systematische

Vorgehensweise aus. D.h., es findet keine Einschränkung auf eine bestimmte Zeitschriftenart oder der geographischen Region statt. Bei der Suche kann zusätzlich die Vorwärts- und Rückwärtssuche angewendet werden. Diese Methode dient als Ergänzung zur Datenbanksuche. Die Vorwärtssuche basiert dabei auf der Suche nach Literatur, welche die gefundene Quelle zitiert. Bei der Rückwärtssuche werden dagegen die zitierten Quellen aus der gefundenen Literatur identifiziert. Beide Suchmethoden zielen darauf ab, weitere relevante Publikationen zu eruieren (Webster & Watson 2002).

Vorgehensmodell

Die SLA wird in mehreren Schritten durchgeführt. Eine übersichtliche Basis bietet das Vorgehensmodell von vom Brocke et al. (2009), das in fünf Phasen gegliedert ist (Abbildung 2).

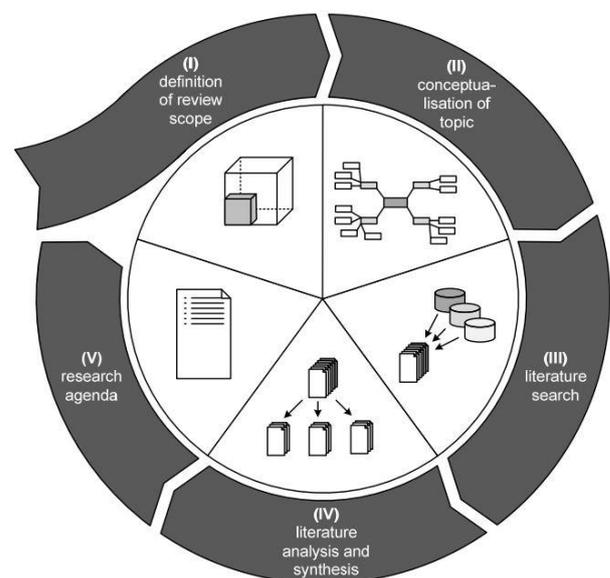


Abbildung 2: Vorgehensmodell der SLA nach vom Brocke et al., 2009

In Phase I wird zunächst der thematische Suchbereich definiert. Hierbei werden relevante Suchkriterien festgelegt (s. Tabelle 1). Phase II beinhaltet die Erstellung eines Suchkonzepts, das ein solides Wissen über das Thema voraussetzt. Der Suchprozess in Phase III umfasst das Anwenden von Datenbanken, Keywords, die Reduzierung auf relevante Literatur sowie die Vorwärts- oder Rückwärtssuche. Der Ausschluss von Literatur erfolgt anhand der Auswertung von Titel, Abstract und Volltexten. Nachdem eine ausreichende Menge relevanter Literatur zusammengetragen werden konnte, wird in Phase IV die Analyse und Synthese der Quellen durchgeführt. Dieser Sortierungsprozess ermöglicht eine Kategorisierung der Publikationen. Schließlich kann eine thematische Einordnung gem. Phase V mit einer Konzeptmatrix von Webster & Watson zusammengefasst und zur Auswertung des aktuellen Forschungsstandes sowie zum Aufdecken von Forschungslücken herangezogen werden (vom Brocke et al. 2009).

Anwendung des Vorgehensmodells

Bevor eine gezielte Literatursuche durchgeführt wird, ist die Definition des zu untersuchenden Forschungsfeldes von entscheidender Bedeutung. Mithilfe des Vorgehensmodells nach vom Brocke et al. (2009), sollen folgende Forschungsfragen beantwortet werden:

1. Welche Rahmenbedingungen müssen zur Umsetzung eines erfolgreichen KI-Projektes in einem Unternehmen gegeben sein?
2. Welche weiteren Maßnahmen ergeben sich nach Evaluierung der Rahmenbedingungen, um die Implementierung von KI erfolgreich zu realisieren?

Das Vorgehensmodell beginnt mit Phase I, bei der zunächst ein grober Rahmen der Ein- und Ausschlusskriterien zur Literatur festgelegt werden. Diese sind in der Tabelle 1 definiert. Da es sich bei dem Thema KI um ein aktuelles und dynamisches Thema handelt, wird die Suche auf veröffentlichte Publikationen der letzten drei Jahre (2019 bis 2022) beschränkt.

Kriterium	Beschreibung
Sprache	Deutsch und Englisch
Zugänglichkeit	Frei zugänglich, Online
Publikationstyp	Keine kurzen Paper (weniger als 2 Seiten, z. B. Poster, redaktionelle Beiträge etc.), keine Abschlussarbeiten
Publikationsinhalt	Keine Duplikate (nach Titel und Inhalt)
	Publikationen mit relevanten Informationen zur Beantwortung der Forschungsfragen

Tabelle 1: Ein- und Ausschlusskriterien der Literatursuche in Anlehnung an Sanchez-Puchol & Pastor-Collado, 2017

Für den nächsten Schritt (Phase II) konnte eine Vorrecherche Aufschluss über den zu untersuchenden Themenbereich geben. Unter Einbeziehung der Ein- und Ausschlusskriterien werden themenbasierte Schlüsselwörter (Keywords) zur Beantwortung der Forschungsfragen definiert. Datenbankeingaben mit Test-Keywords geben Hinweise auf weitere Keywords bzw. Synonyme. Daraus ergibt sich die folgende Abfrage:

((„Künstliche Intelligenz“ OR „artificial intelligence“) AND („Unternehmen“ OR „company“) AND („Einführung“ OR „implement*“ OR „Umsetzungsstrategie“ OR „Konzept*“ OR „concept*“ OR „framework“ OR „Voraussetzung*“ OR „requirement”))

Gem. Phase III werden adäquate Datenbanken festgelegt. Hierzu werden wissenschaftliche und internationale Inhalte herangezogen. Aufgrund der hohen Praxisrelevanz werden zusätzlich praxisorientierte (nicht wissenschaftliche) Quellen betrachtet. Inkludiert werden die Suchmaschinen Google Scholar, IEEE (Institute of Electrical and Electronics Engineers), scinos (scientific information osnabrück) der Hochschule Osnabrück und SpringerLink. Über Google findet zudem eine manuelle Suche

praxisorientierter Quellen statt. Die Suche wurde im Zeitraum vom 20.06. bis 24.06.2022 durchgeführt. Aufgrund des zeitlichen Umfangs wird auf eine Vor- bzw. Rückwärtssuche verzichtet.

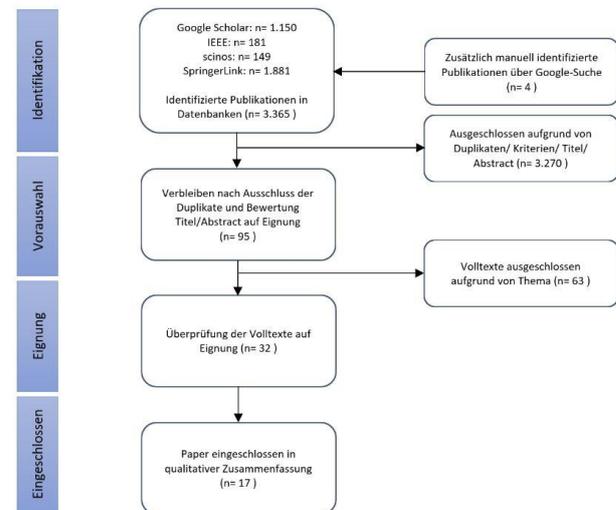


Abbildung 3: Flussdiagramm für den Aussortierungsprozess von Publikationen (in Anlehnung an prisma-statement.org)

Mit der Abfrage wurden 3.365 Treffer in den angegebenen Datenbanken gefunden. Die Abbildung 3 stellt die durchlaufenen Phasen des angewandten Verfahrens dar. Nach Ausschluss der Duplikate, anhand der festgelegten Kriterien, des Titels sowie Sichtung des Abstracts, konnte die Treffermenge um 3.270 Publikationen reduziert werden. Die verbleibenden 95 Publikationen werden nach einer groben Sichtung der Volltexte auf 32 reduziert. In einer finalen Sichtung und Prüfung auf Eignung der 32 Publikationen, werden 17 Paper in die qualitative Zusammenfassung eingeschlossen.

Die inhaltliche Strukturierung der 17 Publikationen erfolgt in einer Konzeptmatrix nach Webster & Watson (s. Tabelle 2). In den Zeilen sind Autor und Erscheinungsjahr und in den Spalten die gefundenen Konzepte dargestellt. Um das systematische Vorgehen bei der Einführung von KI zu strukturieren, sind die Konzepte grob in die beiden Kategorien Ausgangsbasis und Folgemaßnahmen unterteilt. Die Kreuze markieren die inhaltlichen Konzepte der jeweiligen Publikation. Diese werden schließlich aufsummiert und können Aufschluss über die Relevanz spezifischer Handlungsschritte geben.

Konzepte	Ausgangsbasis						Folgemeasures						
	KI-Fachkompetenzen intern/extern	Qualität/ Zugang Datenbasis	Eignung Hardware/ IT-Infrastruktur	(Agiles) Projektmanagement	Klare Zieldefinition/ Konzeption AWF	Kostenfaktoren/ Budget	KI-Plattform (Reife/Marken)	Echtzeitverarbeitung (5G)/ Performance	KPI / Bewertungskriterien	Akzeptanz im Unternehmen/ Geschäftsprozesse anpassen	Datensicherheit/ -schutz	Vorgehensmodell	
Rode-Schubert & Müller, 2020	x	x	x	x		x		x					
Regnerl, 2021		x						x	x		x		
Haarmeier, 2021	x	x	x			x	x						
Stowasser, 2021					x				x	x			
Kern & Sattler, 2020	x	x	x										
Brenner et al., 2021	x	x	x	x	x				x			x	
Pokorni et al., 2021	x	x	x	x	x	x		x	x	x		x	
Petry, 2021	x	x	x			x	x	x	x	x	x	x	
Matzka, 2021		x			x	x						x	
van Giffen et al., 2020	x	x	x		x	x	x	x	x			x	
Herremans, 2021	x	x	x	x	x		x	x				x	
Wuttke, 2022	x	x	x		x		x		x				
Rainsberger, 2021	x	x	x	x	x	x			x	x		x	
Aichele, 2021	x			x	x	x							
Vollhardt et al., 2021	x	x	x	x	x		x					x	
Müller et al., 2021	x	x	x		x	x	x		x	x	x		
Diab et al., 2022		x	x				x	x				x	
Gesamt	13	15	13	7	11	9	8	3	6	9	5	7	3

Tabelle 2: Konzeptmatrix in Anlehnung an Webster & Watson, 2002

Quantitative Literaturlauswertung

Mit der Konzeptmatrix konnte eine quantitative Übersicht der themenbezogenen Konzepte ermittelt werden. In der Kategorie Ausgangsbasis sind die Konzepte definiert, welche die Rahmenbedingungen für den zukünftigen Einsatz von KI festlegen. Diese werden als Voraussetzung erachtet und sollten vor Projektbeginn erfüllt sein. Von diesen sechs Konzepten wurden fünf identifiziert, die in mindestens 50% der vorliegenden Publikationen genannt werden. Am häufigsten werden die Qualität der Datenbasis (88%), KI-Fachkompetenzen (76%) sowie die Eignung der IT-Infrastruktur und Hardware (76%) genannt. Etwa 65% der Publikationen thematisiert zudem, dass eine klare Definition der Ziele bzw. der Entwurf des AWF notwendig sei. Die Bestimmung eines Budgets für die Umsetzung wird dabei in 53% der Fälle genannt. Das (agile) Projektmanagement (PM) erhält mit 41% den kleinsten Anteil aus den genannten Konzepten dieser Kategorie.

Nach Erfüllung der Ausgangsbasis sollten relevante Folgemeasures bei der Projektdurchführung umgesetzt werden. Eines der sieben Konzepte wird in über 50% der Publikationen definiert. Obwohl die weiteren sechs Konzepte diese Schwelle nicht erreicht haben, werden sie als bedeutsamer Bestandteil eines KI-Projektes erachtet. Den höchsten Wert haben in diesem Fall die Schaffung der Akzeptanz und das Vertrauen in KI im Unternehmen (53%) erreicht. Weiterhin sind im oberen Drittel die Nutzung einer KI-Plattform (47%) und die Gewährleistung von Datensicherheit/-schutz (41%) einzuordnen. In den mittleren Bereich fallen das Festlegen von KPIs und Bewertungskriterien (35%), die zur Leistungsmessung der KI-Anwendung notwendig sind, sowie die Anpassung und Optimierung der Geschäftsprozesse (29%), in denen die KI implementiert wird. Die Echtzeitverarbeitung, die über ein 5G Netz realisiert wird und die Anwendung

eines standardisierten Vorgehensmodells, wie dem CRISP-DM, werden dagegen in nur 18% der Fälle beschrieben.

KONZEPTION UND PRAKTISCHE UMSETZUNG

Die quantitative Literaturlauswertung legt die Basis für die Synthese der Ergebnisse und Umsetzung in die Praxis. Aufbauend auf der quantitativen Literaturlauswertung erfolgt in den folgenden Abschnitten die qualitative Literaturlauswertung. Die Rahmenbedingungen und weiteren Maßnahmen für den Einsatz von KI werden anschließend in einem Konzept zusammengefasst.

Voraussetzungen für KI-Projekte

Die Evaluation der qualitativen Literaturlauswertung zeigt die konzeptionelle Relevanz verschiedener Bereiche auf, die bei der Umsetzung von KI-Projekten im Unternehmen als wichtig erachtet werden. KI-Einführungen sind nicht mit der Einführung von Software zu vergleichen. KI setzt sich aus einem Algorithmus, einer qualitativ hochwertigen Datenbasis und Business Intelligence zusammen (Rainsberger 2021). Dabei ist der Algorithmus in den meisten Fällen vom AWF abhängig und kann nicht auf andere AWF übertragen werden (Diab et al. 2022).

Nach Matzka (2021) ist ein sinnvoller Einsatz von KI nur gegeben, wenn der technische und wirtschaftliche Nutzen im Vergleich zum vorherigen Zustand höher ist und der Ressourcenaufwand verringert wird. Zur technischen Umsetzung gibt es bereits standardisierte, methodische Ansätze wie z. B. CRISP-DM. Dieses Modell stellt jedoch nur eine von vielen Projektphasen dar und darf nicht isoliert betrachtet werden (Matzka 2021). Zu Beginn eines KI-Projektes besteht oftmals die Notwendigkeit veraltete IT-Systeme abzulösen oder zu optimieren. KI-Anwendungen können daher erhebliche Investitionen mit sich bringen (Brenner et al. 2021). Nach einer KI-Implementierung sollte der Entwicklungsprozess nicht als abgeschlossen betrachtet werden. KI als neue Technologie wird stetig weiterentwickelt und erfordert die Weiterbildung des Fachpersonals (Herremans 2021).

In den nachstehenden Abschnitten werden die einzelnen Konzepte ausformuliert. Betrachtet werden dabei die wesentlichen Voraussetzungen für den Einsatz von KI, bei denen ein prozentualer Anteil von über 50% in den vorliegenden Publikationen der SLA gegeben ist. In dieser Größenordnung ist davon auszugehen, dass die Konzepte in der Vergangenheit bereits ausreichend erprobt wurden. Die verbleibenden Konzepte werden aufgrund des geringen Bewertungsanteils im Abschnitt ‚Zusammenfassung Ausgangsbasis und Folgemeasures‘ lediglich zusammengefasst.

Trotz weitreichender Recherche haben die aufgeführten Voraussetzungen keinen Anspruch auf Vollständigkeit. Zudem ist zu berücksichtigen, dass KI ein dynamisches Forschungsfeld darstellt (Gethmann et al. 2022) und sich aufgrund neuer Forschungserkenntnisse zukünftig verändern kann.

Qualität der Datenbasis

Daten sind in den vorliegenden Publikationen ein entscheidender Faktor für die erfolgreiche Einführung von KI. Für KI- und ML-Anwendungen bilden Daten die Ausgangsbasis. Dabei nehmen die Beschaffung und die Aufbereitung der Daten in der erforderlichen Qualität etwa 80% des Projektaufwands in Anspruch. Das Scheitern von KI-Projekten ist in vielen Fällen auf eine schlechte Datenverfügbarkeit und -qualität zurückzuführen (Brenner et al. 2021). Dies trifft ebenfalls bei einer zu kleinen Datenbasis zu, da zum Trainieren eines brauchbaren Modells eine ausreichend große Datenbasis zur Verfügung stehen muss (Müller et al. 2021).

Nach Rode-Schubert & Müller (2020) muss im Unternehmen die Voraussetzung erfüllt sein, dass die relevanten Daten aus dem System ausgelesen und von Fachpersonal aufbereitet und bereinigt werden können. Hierbei sind die korrekte Selektion und eine geringe Fehlerquote der Daten, wie auch ein ausreichendes Datenvolumen entscheidend. Eine schlechte Datenbasis mit geringem Umfang kann zu fehlerhaften oder ungenügenden Ergebnissen führen. Dabei müssen teils auch Daten aus heterogenen Anwendungssystemen zusammengeführt und integriert werden. Werden diese Schritte nicht gewissenhaft durchgeführt, könnte eine Nutzung fehlerhafter oder unvollständiger Daten dazu führen, dass der Algorithmus keinen Zusammenhang findet. Eine hohe Datenqualität bildet die Voraussetzung zur Gewinnung verwendbarer Analyseergebnisse (Rode-Schubert & Müller 2020).

KI-Fachkompetenzen

Eine gute Datenqualität ist neben dem umfangreichen Know-how im Bereich KI und Data Science von entscheidender Bedeutung. Mithilfe der Techniken aus dem Bereich Data Science können Berechnungsmethoden zur Identifikation von Mustern und Strukturen in Datensätzen beitragen und prägnante Modelle zur Visualisierung generiert werden (Pokorni et al. 2021). Data Scientists verfügen über methodische Kenntnisse in der Anwendung von KI und ML. Die Tätigkeiten eines Data Scientist beinhalten einerseits die Auswahl und Bereinigung sowie die Herstellung der geforderten Datenqualität. Darüber hinaus ist die Vorbereitung für die Modellierung, Transformation und Integration der Daten und deren Verarbeitung ebenso wichtig wie die Analyse und Bewertung von statistischen Ergebnissen. Die Fähigkeit zum Visualisieren der erstellten Modelle verhilft dabei, bessere Aussagen bei der Untersuchung der Qualität und potenziellen Fehlerquellen zu treffen (Keim & Sattler 2020). Beim Aufbau dieser Kompetenzen müssen Unternehmen entscheiden, ob eine interne Ausbildung durchgeführt wird oder ob externe Dienstleister oder Berater herangezogen werden. Eine weitere Möglichkeit bietet die Einstellung von Fachpersonal. Aufgrund des Fachkräftemangels kann sich diese Entscheidung jedoch als langwieriger Prozess herausstellen (Rainsberger 2021). Neben den Kompetenzen als Data Scientist sind in KI-Projekten aus technischer Sicht weitere Fähigkeiten erforderlich. Beispielsweise programmieren Softwareentwickler notwendige Schnittstellen in der IT-Infra-

struktur, während weiteres Fachpersonal den Überblick auf Anforderungen und Probleme im Unternehmen behalten und diese analysieren muss (Pokorni et al. 2021; Rainsberger 2021). Die Verfügbarkeit von adäquaten Fachkompetenzen stellt für KI-Projekte einen wesentlichen Bestandteil dar und kann bereits zu Beginn der Planung eine Herausforderung bedeuten.

Eignung der IT-Infrastruktur

Die IT-Infrastruktur dient dazu, Daten über Hard- und Softwarekomponenten für die Analyse verfügbar zu machen. Im Sinne von KI soll die IT-Infrastruktur eine effiziente, störungssichere und skalierbare Datenverfügbarkeit bereitstellen. Verschiedene Komponenten sollen optimal aufeinander abgestimmt sein, um die technischen Voraussetzungen für KI zu ermöglichen (Petry 2021). Dabei ist die technische Leistung der IT-Infrastruktur vom Innovationsgrad der KI abhängig. Ein stärkerer Innovationsgrad benötigt leistungsstarke Server, Speicher sowie Hard- und Software (Brenner et al. 2021). Bei der Datenspeicherung ist festzulegen, ob und welche Daten auf eigenen Servern abgelegt werden und inwiefern auf eine Cloud-Lösung zurückgegriffen werden soll. Dabei sollten die Aspekte Datenschutz bei sensiblen Daten (Herremans 2021) und die Datentransferrate in Bezug auf KI beachtet werden. Die notwendigen Schnittstellen für die Datenströme der IT-Infrastruktur müssen eine gute Performance für die KI bieten. Hierbei ist insbesondere die Möglichkeit zur Verarbeitung von großen Datenmengen zu berücksichtigen. Außerdem kann bei einigen Algorithmen eine spezielle Hardware erforderlich sein (Diab et al. 2022), die es zu beachten gilt. Zudem muss bei der eingesetzten Software Interoperabilität gegeben sein, die bei einem Einsatz von verschiedenen KI-Softwarekomponenten eine leistungsfähige KI ermöglicht (Rode-Schubert & Müller 2020).

Klare Zieldefinition

Mit einer präzisen Zieldefinition können Lösungsansätze im angemessenen Umfang entwickelt werden. Dabei sollte der Algorithmus nicht im Vordergrund stehen. Generell sollte der Fokus auf die Optimierung des wirtschaftlichen Mehrwertes liegen (Wuttke 2022). Eine objektive Analyse soll Aufschluss über die Fragen geben, welchen Nutzen die zukünftige KI-Anwendung erfüllen soll. Dies können z. B. die Steigerung des Return on Investment (ROI) oder ein Wettbewerbsvorteil gegenüber der Konkurrenz sein (Petry 2021). Neben der Zieldefinition sorgt eine Potenzialanalyse und Abschätzung der technischen und sozialen Auswirkungen für den nötigen Weitblick. Zielkonflikte und Risiken können bereits im Vorfeld identifiziert und Potenziale ergriffen werden (Stowasser 2021). Der Einsatz von Planungswerkzeugen (z. B. KI-Canvas) kann bei der Formulierung unterstützend wirken, um den Prozess strukturiert und übersichtlich abzubilden. Dabei können einzelne Karten mit der konkreten Fragestellung oder Zieldefinition formuliert und schrittweise konkretisiert werden. Diese geben beispielsweise Aufschluss über die erforderlichen Input-

Daten für das KI-Modell, den erwarteten Output oder die Definition relevanter KPIs (Müller et al. 2021).

Kostenfaktoren

Ein weiteres Kriterium sind die entstehenden Kosten, die mit einem KI-Projekt einhergehen. Das vorhandene Budget sollte vor Beginn des KI-Projektes mit den zukünftigen Kosten abgeglichen werden. Eine gründliche Abschätzung entstehender Kosten ist für den Erfolg des KI-Projektes unabdingbar. Diese können grob in Verwaltungs-, Entwicklungs-, Software- und Implementierungskosten unterteilt werden (Rainsberger 2021).

Wie bereits im Abschnitt ‚KI-Fachkompetenzen‘ beschrieben, ist qualifiziertes Fachpersonal in verschiedenen Bereichen erforderlich. Je nach Vorhandensein von verfügbarem Fachpersonal im Unternehmen sind interne und externe Personalkosten zu berücksichtigen. Diese sind mit der richtigen Qualifikation und in angemessener Anzahl einzusetzen. Alternativ sind Kosten für die Aus- und Weiterbildung zu berücksichtigen. Beim Einsatz einer Cloud sind die anfallenden Kosten abhängig von der Nutzung und der Speicherkapazität sowie der Preisgestaltung des Anbieters. Betriebskosten der zukünftigen KI-Anwendung fallen ebenfalls in die Kostenschätzung (Petry 2021). KI-Software wird für z. B. die Erstellung eigener Modelle genutzt. Die Kosten sind abhängig vom Funktionsumfang. Zu den Implementierungskosten zählen u. a. die Programmierung von Schnittstellen und die Integration in bestehende Systeme (Rainsberger 2021).

Im ersten Projektjahr ist vor allem mit Entwicklungskosten für die KI-Anwendung zu rechnen und evtl. mit Investitionen zur Anpassung der IT-Infrastruktur. Kosten für Weiterentwicklung, Wartung, interne und externe Personalkosten und sonstige Kosten fallen im gesamten Betrachtungszeitraum des Projektes an (Aichele 2021).

Zusammenfassung Ausgangsbasis und Folgemaßnahmen

In diesem Abschnitt werden die Konzepte der Ausgangsbasis mit der Bewertung unter 50% betrachtet und mit den Folgemaßnahmen zusammengeführt.

Das PM erreicht in der Auswertung einen Wert von 41% einen eher geringen Anteil, obwohl die sorgfältige Planung und Durchführung von KI-Projekten nach eigener Einschätzung einen hohen Stellenwert haben. Das aufgestellte Personal in einem KI-Team sollte dabei über grundlegendes Fachwissen digitaler Prozesse (Pokorni et al. 2021) und interner Betriebsabläufe verfügen (Herremans 2021). Bei der Wahl der PM-Methode wird zwischen dem klassischen und agilen PM unterschieden. Der klassische Ansatz wird zunehmend durch das agile PM ersetzt. Bei KI-Projekten eignet sich das agile PM mit iterativen Vorgehen (Aichele 2021; Rode-Schubert & Müller 2020).

Nach Definition der Voraussetzungen, die zu Beginn eines KI-Projektes bestimmt sein sollten, sind weitere Maßnahmen zu ergreifen. Die ermittelten Konzepte in der Kategorie Folgemaßnahmen sind alle mit einem Wert unter 50% bewertet. Dennoch sind die Folgemaßnahmen

Bestandteil eines KI-Projektes und nicht auszuschließen. Im Folgenden werden die zentralen Aussagen zusammengeführt.

Die größte Relevanz fällt mit 47% auf KI-Plattformen sowie Akzeptanz von KI im Unternehmen. Haarmeier (2021) definiert KI-Plattformen als Cloud-basierte Services (KI-as-a-Service), mit denen Lösungen als Entwicklungsumgebung für ML-Modelle zur Verfügung gestellt werden. Da die Plattformen auf bestimmte AWF spezialisiert sind, sollte vor Auswahl der KI-Plattform der konkrete AWF definiert sein. Für KMU bieten sie einen guten Einstieg, da eine Einrichtung eigener Hard- und Software entfällt. Ein weiterer Vorteil ist die Skalierbarkeit, die z. B. bei Modellen mit großer Rechenleistung angepasst werden kann (Haarmeier 2021). Bei KI-Plattformen ist auf Datenschutz zu achten, der bei der Verarbeitung personenbezogener Daten zu gewährleisten ist. Flexible Plattformen sollten sich leicht um neue Komponenten erweitern lassen und neue Technologien und Datentypen zulassen (Petry 2021).

In der Vergangenheit haben Verzerrungen von Daten oder Bias zu fehlerhaften Entscheidungen von KI-Algorithmen beigetragen. Diese Bias sind auf unvollständige Trainingsdaten zurückzuführen und haben daraufhin z. B. ethnische Gruppen unterschiedlich behandelt. Dies ist eines von vielen Beispielen, die das Vertrauen und die Akzeptanz von KI reduzieren (van Giffen et al. 2020). Nach Stowasser (2021) sollten vor der Implementierung von KI-Anwendungen die Akzeptanz der Mitarbeiter im Unternehmen und das allgemeine Vertrauen in KI gewährleistet sein. Es ist daher erforderlich für Transparenz im Unternehmen zu sorgen und das Verfahren der KI zu erläutern. Mitarbeiter sollten über technische, soziale und positive wirtschaftliche Auswirkungen geschult werden. Dabei sollen die Transparenz und Erklärbarkeit der Entscheidungen von KI nachvollzogen werden können. Je nach AWF müssen Mitarbeiter ggf. auf neue Arbeitsprozesse vorbereitet und qualifiziert werden (Stowasser 2021). Bei einer Interaktion zwischen Mensch und Maschine muss dem Menschen die Möglichkeit gegeben sein, bei der endgültigen Entscheidung auf die maschinelle Entscheidungsunterstützung zu verzichten (Pokorni et al. 2021).

In puncto Vertrauen nehmen Datenschutz und Datensicherheit im Unternehmen einen hohen Stellenwert ein, der insbesondere durch die hohe Datenabhängigkeit der KI bedingt wird. IT-Systeme müssen daher bestimmte Sicherheitsstandards erfüllen (Diab et al. 2022) und die datenschutzkonforme Verarbeitung personenbezogener Daten gemäß Datenschutz-Grundverordnung (DSGVO) sicherstellen (Rainsberger 2021).

Mit KPIs kann die wirtschaftliche Leistung eines Unternehmens gemessen werden. Diese können auch zur Leistungsbewertung der KI-Anwendung herangezogen werden, um dessen Kosten-Nutzen-Verhältnis zu eruiieren (Herremans 2021). Die Leistung der KI-Anwendung kann ohne die Bestimmung von KPIs nicht gemessen werden (Petry 2021). Nach Pokorni et al. (2021) sollten vor der betrieblichen Einführung umfassende Prüfungen im Hinblick auf die Funktionalitäten, Genauigkeit, Bias,

Nutzerakzeptanz und Usability sowie der Mehrwert für das Unternehmen vorgenommen werden. Auffälligkeiten können daraufhin behoben und ggf. weiter verfeinert werden (Pokorni et al. 2021).

Wie bereits im Abschnitt ‚Eignung der IT-Infrastruktur‘ beschrieben, müssen mit einer KI-Einführung individuelle Anpassungen in der IT-Infrastruktur vorgenommen werden. Unternehmen sollten die Chance ergreifen, den jeweiligen AWF vor der Digitalisierung zu optimieren oder neu zu gestalten. Damit soll vermieden werden, dass ein schlechter Prozess in einen schlechten Prozess mit einer KI-Anwendung überführt wird (Rainsberger 2021).

In 18% der Fälle wird auf ein Vorgehensmodell zurückgegriffen, das einen iterativen Ansatz zur Strukturierung von KI-Projekten beschreibt. Ein standardisiertes Modell ist CRISP-DM, das die sechs Projektphasen Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation und Deployment beschreibt (Matzka 2021). Brenner et al. (2021) schildern, dass die wachsende Komplexität, die z. B. bei der Datenverarbeitung und -speicherung im Sinne von Big Data mit sich bringt, kaum berücksichtigt wird. Aufgrund von weiteren Kritikpunkten erarbeitete IBM die Analytics Solution Unified Method for Data Mining (ASUM-DM) als optimiertes Modell in Anlehnung an CRISP-DM. Ein weiteres Vorgehensmodell stellt der Team Data Science Process (TDSP) von Microsoft dar. Dieses Modell involviert u. a. die Aspekte Teamzusammenarbeit, Lernen, Agilität und ist primär für Projekte der prädiktiven Analytik geeignet, z. B. in Verbindung mit KI (Brenner et al. 2021). Je nach AWF kann eines dieser Modelle als Ergänzung dienen bzw. in das KI-Projekt integriert werden.

Große Datenmengen, insbesondere Big Data, erfordern eine robuste Netzwerk- und IT-Infrastruktur sowie eine angemessene Bandbreite und Latenz. Sind die Voraussetzungen nicht gegeben, kann die KI-Anwendung nicht zuverlässig arbeiten (Diab et al. 2022). Sofern diese für eine Echtzeitverarbeitung eingesetzt wird, ist die Verwendung einer 5G Breitbandverbindung vonnöten (Rode-Schubert & Müller 2020).

Empfehlungen zur Vorgehensweise

Aufgrund der chronologisch absteigenden Aufstellung nach der quantitativen Auswertung der Publikationen ist keine Handlungsreihenfolge vorgegeben. Diese basiert primär auf der ausführlichen Erläuterung. Für eine praxisorientierte Anwendung kann ein Schaubild zur besseren Übersicht beitragen. In Abbildung 4 wird eine Handlungsreihenfolge als modellhafte Nachbildung der einzelnen Projektphasen beispielhaft dargestellt. Dabei wird die bisherige Kategorisierung in ‚Ausgangsbasis‘ und ‚Folgemaßnahmen‘ aus der SLA verfeinert. Die einzelnen Projektphasen fassen die Handlungen zur besseren Orientierung zusammen. Dabei können die Handlungen fließend in die nachfolgende Phase übergehen.

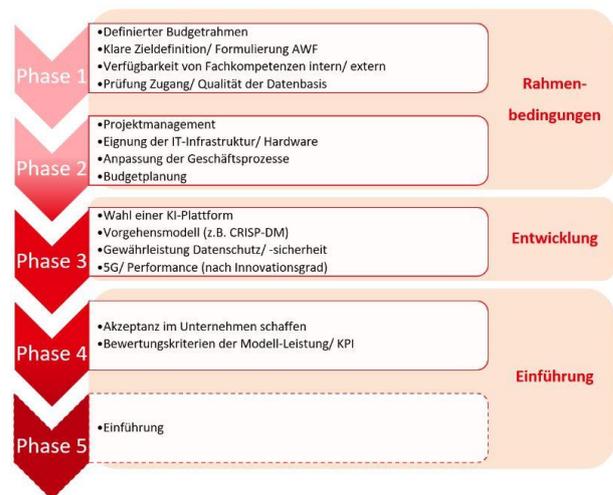


Abbildung 4: Überblick der Projektphasen zur Orientierung für KI-Projekte (Eigene Darstellung)

In Phase 1 sollte zunächst ein vorhandener Budgetrahmen vorliegen. Ohne ein ausreichendes Budget können nachfolgende Schritte nicht oder nur teilweise umgesetzt werden. Hierbei wird die kombinierte Kalkulation mit der Budgetplanung in Phase 2 empfohlen. Weiterhin ist es erforderlich das Ziel des KI-Projektes zu benennen. Eine zusätzliche Formulierung des AWF schafft Klarheit und Handlungssicherheit bei der Planung weiterer Schritte. Zudem ist zu berücksichtigen, ob interne oder externe Fachkompetenzen mit der richtigen Niveaustufe und in ausreichendem Umfang verfügbar sind. Ein erfolgsentscheidender Faktor ist der Zugang zur Datenbasis sowie eine ausreichende Quantität und Qualität. Diese ist durch Fachpersonal zu bewerten und nach Notwendigkeit aufzubereiten. Sofern diese Bedingungen gegeben sind, kann in Phase 2 sowohl das PM-Team zusammengestellt als auch die PM-Methode festgelegt werden. Der mit einer KI-Anwendung auszustattende Geschäftsprozess ist auf Optimierungspotenzial zu untersuchen und muss bei Bedarf angepasst werden. In einem weiteren Schritt besteht die Anforderung, die bestehende IT-Infrastruktur und Hardware von Fachpersonal auf Eignung zu überprüfen. Einzelne Anpassungen bis hin zur kompletten Umstrukturierung sind dabei denkbar. Diese sind neben den zusätzlichen Kosten gemäß der genannten Kostenfaktoren in der Budgetplanung zu berücksichtigen. Sofern diese Rahmenbedingungen zur Realisierung des KI-Projektes gegeben sind, findet ab Phase 3 die Umsetzung weiterer Maßnahmen statt. Da in dieser Phase die Entwicklung des Modells durchgeführt wird, kann sie auch als Entwicklungsphase bezeichnet werden. Für die Modellierung wählt das Fachpersonal in Anlehnung an die Anforderungen des AWF eine adäquate KI-Plattform als Entwicklungsumgebung. Die vorgestellten Vorgehensmodelle, wie etwa CRISP-DM, sollten nicht isoliert betrachtet werden und Teil des Projektes sein. Da in diesem Fall bereits ein Grundgerüst definiert ist, könnte eines der vorgestellten Vorgehensmodelle als Ergänzung und Unterstützung in der Modellentwicklung eingesetzt werden. Dies betrifft beispielsweise die Phasen Datenanalyse, -visualisierung, -vorbereitung, -bereinigung,

sowie maschinelle Modellbildung und Evaluation des maschinellen Modells (Matzka 2021). Bereits während der Entwicklungsphase ist es sinnvoll zu eruieren, inwiefern die Aspekte Datenschutz und -sicherheit integriert werden müssen. Je nach Innovationsgrad der KI-Anwendung ist die Bereitstellung einer 5G Breitbandverbindung zur Verarbeitung von Echtzeitdaten frühzeitig zu veranlassen, damit dieser termingerecht zur Implementierung bzw. zu Testzwecken zur Verfügung steht. In der Einführungsphase bedarf es in Phase 4 die Akzeptanz von KI im Unternehmen, die beispielsweise mit Mitarbeiterschulungen die Entscheidungsfindung der KI-Anwendung näherbringt und Vertrauen schafft. In diesem Zusammenhang können Mitarbeiter ausgebildet werden, die unmittelbar mit der KI-Anwendung arbeiten. Schließlich sollten ausgiebige Tests vor der Einführung durchgeführt werden, um mögliche Funktionsfehler zu eliminieren. Mit definierten KPIs kann zudem die Modelleleistung gemessen werden. Der anschließende Einführungsprozess ist nicht Bestandteil dieser Konzeption, weswegen auf diesen Teil nicht weiter eingegangen wird. Resümierend stellt die Konzeption wichtige Handlungsfelder dar, mit denen die Einführung von KI realisiert werden kann. Aufgrund der Individualität, die beispielsweise vom technischen Fortschritt im Unternehmen oder dem Innovationsgrad der zukünftigen KI-Anwendung abhängig ist, stellen die Konzepte lediglich eine mögliche Verfahrensweise dar. Da ein starrer Leitfaden bei einer neuen und dynamischen Technologie als nicht zielführend erachtet wird, sollte eine Handlungsempfehlung ebenso dynamisch einsetzbar sein. Das Überspringen von Konzepten oder Ergreifen unternehmensspezifischer Angleichungen kann für die Umsetzung ebenfalls erforderlich sein und unterliegt einer individuellen Bewertung.

FAZIT

Mit der konzipierten Handlungsempfehlung können Unternehmen mehr Sicherheit bei der Planung und Umsetzung von KI-Projekten erlangen. Relevante Rahmenbedingungen konnten mithilfe der SLA den Handlungsbedarf bei KI-Projekten ermitteln. Mit den zusätzlich identifizierten Maßnahmen stellen sie zusammengefasst die Handlungsempfehlung dar. Diese ist dabei als allgemeine Orientierung zu betrachten und an die internen Gegebenheiten im Unternehmen und den Innovationsgrad des KI-Projektes anzupassen.

Als relevante Rahmenbedingungen wird die Definition des Budgetrahmens, eine klare Zieldefinition des AWF sowie die Verfügbarkeit von Fachpersonal mit umfassenden Methoden- und Anwendungswissen herauskristallisiert. Im PM-Team erfolgt die Planung des KI-Projektes, die unter Berücksichtigung der vorliegenden Voraussetzungen evaluiert wird. Dazu zählen die Eignung der IT-Infrastruktur und Hardware sowie die Ausführung von unternehmensspezifischen Optimierungen am Geschäftsprozess. Fehlendes Know-how muss durch Aus- und Weiterbildung interner Fachkräfte oder Einstellung externer Dienstleister kompensiert werden. Aus diesen Aspekten resultiert u. a. die Budgetplanung, deren sorgfältige Ausgestaltung aufbauend zum vorhandenen Budget

sorgfältig kalkuliert werden sollte und wesentlich zum Projekterfolg beiträgt.

In der Entwicklungsphase sollte ein geeignetes Vorgehensmodell (z. B. CRISP-DM) zur Strukturierung des Datenmanagements verwendet werden. Eine AWF-spezifische KI-Plattform kann dabei als Entwicklungsumgebung dienen. Zudem sollte ein Konzept zur Umsetzung des Datenschutzes und der Datensicherheit frühzeitig geplant werden. Dies gilt entsprechend für eine gute Bandbreite und Performance über eine 5G Breitbandverbindung bei potenzieller Echtzeitverarbeitung. Aus Gründen der Transparenz und Steigerung des Vertrauens in die KI-Anwendung, sollten Mitarbeiter in die Entscheidungsfindung und Funktionsweise mit einbezogen werden. Schließlich ist eine Bewertung zur Leistung der KI-Anwendung mit ausgewählten KPIs vorzunehmen, die zur Messung des Erfolges herangezogen werden. Im Idealfall weist das Ergebnis einen positiven Nettonutzen auf.

Die Handlungsempfehlungen zeigen die Anforderungen verschiedener Tätigkeitsbereiche auf, die bei der Einführung von KI entstehen. Eine KI-Implementierung lässt sich mit der strukturierten Vorgehensweise über die Handlungsempfehlung und unter Berücksichtigung der unternehmensspezifischen Gegebenheiten umsetzen.

Mit kleinen KI-Projekten wird schrittweise Klarheit und Know-how aufgebaut. Der umfangreiche Handlungsbedarf, der mit KI-Projekten einhergeht, ist nicht zu unterschätzen. Andererseits kann eine erfolgreich implementierte KI bedeutende Entwicklungschancen freisetzen. In den nächsten Jahren werden KI-Einführungen aufgrund des großen Potenzials voraussichtlich weiter voranschreiten. Die Vorteile von automatisierten und ressourcensparenden Prozessen können zum zukünftigen Erfolg und einer soliden Wettbewerbsfähigkeit beitragen.

LITERATUR

- Aichele, C. (2021): „Vorgehensweise zur Anwendung Digitaler Geschäftsprozesse auf Basis von Künstlicher Intelligenz“. In: Aichele, C. & Herrmann, J. [Hrsg.] (2021): *Betriebswirtschaftliche KI-Anwendungen*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 75–119.
- Alpaydin, E. (2022): *Maschinelles Lernen*. De Gruyter Oldenbourg, Berlin, Boston. DOI: 10.1515/9783110740196.
- Bolkart, J. (2022): *Statistiken zum Thema Künstliche Intelligenz*. Verfügbar unter: <https://de.statista.com/themen/3103/kuenstliche-intelligenz/?msclkid=bb26b736cf7611ec88069f361bfe263c#dossierKeyfigures>, [Letzter Zugriff: 11 Mai 2022].
- Brenner, W., van Giffen, B., Koehler, J., Fahse, T. & Sagodi, A. (2021): „Stand in Wissenschaft und Praxis“. In: Brenner, W., van Giffen, B., Koehler, J., Fahse, T. & Sagodi, A. [Hrsg.] (2021): *Bausteine eines Managements Künstlicher Intelligenz*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 17–23.
- Buxmann, P. & Schmidt, H. (2019): *Künstliche Intelligenz*, Berlin, Heidelberg, Springer Berlin Heidelberg. DOI: 10.1007/978-3-662-57568-0.

- Cao, L. (2017): „Data science“. In: *Communications of the ACM*, Vol. 60, No. 8, S. 59–68. DOI: 10.1145/3015456.
- Deloitte Deutschland (2020): *KI-Studie 2020: Wie nutzen Unternehmen Künstliche Intelligenz?: KI-relevante Technologien, Strategien, Skills & Herausforderungen in der Praxis*. Verfügbar unter: <https://www2.deloitte.com/de/de/pages/technology-media-and-telecommunications/articles/ki-studie-2020.html>, [Letzter Zugriff: 11 Mai 2022].
- Diab, W. W., Ferraro, A., Klenz, B., Lin, S.-W., Liongari, E., Tannous, W. E. & Zarkout, B. (2022): *Industrial IoT Artificial Intelligence Framework*. Verfügbar unter: <https://www.iiconsortium.org/pdf/Industrial-AI-Framework-Final-2022-02-21.pdf>, [Letzter Zugriff: 24 Juni 2022].
- Fayyad, U., Piatetsky-Shapiro, G. & Smyth, P. (1996): *Knowledge Discovery and Data Mining: Towards a Unifying Framework*. Verfügbar unter: <https://www.aaai.org/Papers/KDD/1996/KDD96-014.pdf>, [Letzter Zugriff: 17 Juli 2022].
- Fettke, P. (2006): „State-of-the-Art des State-of-the-Art“. In: *WIRTSCHAFTSINFORMATIK*, Vol. 48, No. 4. DOI: 10.1007/s11576-006-0057-3.
- Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V. (2018): *Maschinelles Lernen: Eine Analyse zu Kompetenzen, Forschung und Anwendung*. Verfügbar unter: https://www.bigdata-ai.fraunhofer.de/content/dam/bigdata/de/documents/Publikationen/Fraunhofer_Studie_ML_201809.pdf, [Letzter Zugriff: 31 Mai 2022].
- Gethmann, C. F., Buxmann, P., Distelrath, J., Humm, B. G., Lingner, S., Nitsch, V., Schmidt, J. C. & Spiecker genannt Döhmann, I. (2022): *Künstliche Intelligenz in der Forschung*, Berlin, Heidelberg, Springer Berlin Heidelberg. DOI: 10.1007/978-3-662-63449-3.
- Haarmeier, M. (2021): „Künstliche Intelligenz für den Mittelstand“. In: Haarmeier, M. [Hrsg.] (2021): *Künstliche Intelligenz für den Mittelstand*, Wiesbaden, Springer Fachmedien Wiesbaden.
- Han, J., Kamber, M. & Pei, J. (2011): *Data mining: Concepts and techniques*, 3. Aufl., s.l., Elsevier professional. Verfügbar unter: <http://lib.myilibrary.com/detail.asp?id=317117>, [Letzter Zugriff: 20 Juli 2022].
- Herremans, D. (2021): „aiSTROM—A Roadmap for Developing a Successful AI Strategy“. In: *IEEE Access*, Vol. 9, S. 155826–155838. DOI: 10.1109/ACCESS.2021.3127548.
- Humm, B. G., Buxmann, P. & Schmidt, J. C. (2022): „Grundlagen und Anwendungen von KI“. In: Gethmann, C. F., Buxmann, P., Distelrath, J., Humm, B. G., Lingner, S., Nitsch, V., Schmidt, J. C. & Spiecker genannt Döhmann, I. [Hrsg.] (2022): *Künstliche Intelligenz in der Forschung*, Berlin, Heidelberg, Springer Berlin Heidelberg, S. 13–42.
- Keim, D. & Sattler, K.-U. (2020): *Von Daten zu KI: Intelligentes Datenmanagement als Basis für Data Science und den Einsatz Lernender Systeme*, München. Verfügbar unter: https://www.plattform-lernendesysteme.de/files/Downloads/Publikationen/AG1_Whitepaper_Von_Daten_zu_KI.pdf, [Letzter Zugriff: 27 Juni 2022].
- Kleesiek, J., Murray, J. M., Strack, C., Kaissis, G. & Braren, R. (2020): „Wie funktioniert maschinelles Lernen?“. In: *Der Radiologe*, Vol. 60, No. 1, S. 24–31. DOI: 10.1007/s00117-019-00616-x.
- Kotu, V. & Deshpande, B. (2019): „Introduction“ (2019): *Data Science*, Elsevier, S. 1–18.
- Luber, S. & Litzel, N. (2020): *Was ist Data Science?* Verfügbar unter: <https://www.bigdata-insider.de/was-ist-data-science-a-979153/>, [Letzter Zugriff: 29 Juli 2022].
- Matzka, S. (2021): „Daten vorbereiten und bereinigen“. In: Matzka, S. [Hrsg.] (2021): *Künstliche Intelligenz in den Ingenieurwissenschaften*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 59–97.
- Mockenhaupt, A. (2021): „Weitere Werkzeuge der Künstlichen Intelligenz“. In: Mockenhaupt, A. [Hrsg.] (2021): *Digitalisierung und Künstliche Intelligenz in der Produktion*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 199–215.
- Müller, A., Schröder, H. & Thienen, L. von (2021): „Künstliche Intelligenz: Roadmap zur Aufdeckung und Realisierung der KI-Potenziale in der Prozessdigitalisierung“. In: Müller, A., Schröder, H. & Thienen, L. von [Hrsg.] (2021): *Digineering*, Berlin, Heidelberg, Springer Berlin Heidelberg, S. 77–92.
- Murphy, K. P. (2012): *Machine learning - a probabilistic perspective: Adaptive computation and machine learning series*. The MIT Press. Verfügbar unter: <https://www.cs.ubc.ca/~murphyk/MLbook/pml-intro-22may12.pdf>, [Letzter Zugriff: 1 Juni 2022].
- Petry, S. (2021): „KI – von der Strategie zum Projekt“. In: Terstiege, M. [Hrsg.] (2021): *KI in Marketing & Sales – Erfolgsmodelle aus Forschung und Praxis*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 337–387.
- Pokorni, B., Braun, M. & Knecht, C. (2021): *Menschzentrierte KI-Anwendungen in der Produktion: Praxiserfahrungen und Leitfaden zu betrieblichen Einführungsstrategien*. Verfügbar unter: <http://publica.fraunhofer.de/dokumente/N-6249564.html>, [Letzter Zugriff: 27 Juni 2022].
- Rainsberger, L. (2021): „Was tun: Handlungsempfehlungen für Vertriebsorganisationen“. In: Rainsberger, L. [Hrsg.] (2021): *KI – die neue Intelligenz im Vertrieb*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 119–148.
- Robert Bosch GmbH (o. J.): *Die Geschichte der Künstlichen Intelligenz: Von Turing bis Watson: Die Entwicklung der denkenden Systeme*. Verfügbar unter: <https://www.bosch.com/de/stories/geschichte-der-kuenstlichen-intelligenz/>, [Letzter Zugriff: 1 Juni 2022].
- Rode-Schubert, C. & Müller, P. (2020): „Welche Fähigkeiten benötigt ein Unternehmen um Künstliche Intelligenz nachhaltig erfolgreich einzusetzen?“. In: Pfanstiel, M. A. & Steinhoff, P. F.-J. [Hrsg.] (2020): *Transformationsvorhaben mit dem Enterprise*

- Transformation Cycle meistern*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 143–171.
- Sanchez-Puchol, F. & Pastor-Collado, J. A. (2017): „Focus Area Maturity Models: A Comparative Review“. In: Themistocleous, M. & Morabito, V. [Hrsg.] (2017): *Information Systems*, Cham, Springer International Publishing, S. 531–544.
- Shi, L. & Zhu, Q. (2022): „Association Rule Analysis of Influencing Factors of Literature Curriculum Interest Based on Data Mining“. In: *Computational intelligence and neuroscience*, Vol. 2022, S. 6866134. DOI: 10.1155/2022/6866134.
- Stowasser, S. (2021): „Erfolgreiche Einführung von KI im Unternehmen“. In: Knappertsbusch, I. & Gondlach, K. [Hrsg.] (2021): *Arbeitswelt und KI 2030*, Wiesbaden, Springer Fachmedien Wiesbaden, S. 145–153.
- Streim, A. & Uhl, M. (2020): *Unternehmen tun sich noch schwer mit Künstlicher Intelligenz*. Verfügbar unter: <https://www.bitkom.org/Presse/Presseinformation/Unternehmen-tun-sich-noch-schwer-mit-Kuenstlicher-Intelligenz>, [Letzter Zugriff: 11 Mai 2022].
- Suresh, H. & Guttag, J. (2021): „A Framework for Understanding Sources of Harm throughout the Machine Learning Life Cycle“, *Equity and Access in Algorithms, Mechanisms, and Optimization*. -- NY USA, 05 10 2021 09 10 2021. New York, NY, USA, ACM, S. 1–9.
- TURING, A. M. (1950): „I.—COMPUTING MACHINERY AND INTELLIGENCE“. In: *Mind*, LIX, No. 236, S. 433–460. DOI: 10.1093/mind/LIX.236.433.
- van Giffen, B., Borth, D. & Brenner, W. (2020): „Management von Künstlicher Intelligenz in Unternehmen“. In: *HMD Praxis der Wirtschaftsinformatik*, Vol. 57, No. 1, S. 4–20. DOI: 10.1365/s40702-020-00584-0.
- VDMA - Verband Deutscher Maschinen- und Anlagenbau e.V. (2021): *Künstliche Intelligenz – Navigator durch die globale KI-Startup-Szene für den Maschinen- und Anlagenbau*. Verfügbar unter: <https://www.werkstatt-betrieb.de/a/news/erfolgsmotor-kuenstliche-intelligenz-316466>, [Letzter Zugriff: 22 Juli 2022].
- vom Brocke, J., Simons, A., Niehaves, B., Niehaves, B., Reimer, K., Plattfaut, R. & Cleven, A. (2009): *Reconstructing the giant: On the importance of rigour in documenting the literature search process*. Verfügbar unter: <https://aisel.aisnet.org/ecis2009/161>, [Letzter Zugriff: 29 Juli 2022].
- Weber, F. (2020): *Künstliche Intelligenz für Business Analytics: Algorithmen, Plattformen und Anwendungsszenarien*, Wiesbaden, Heidelberg, Springer Vieweg. DOI: 10.1007/978-3-658-29773-2.
- Webster, J. & Watson, R. T. (2002): *Analyzing the past to prepare for the future: writing a literature review*, MIS Quarterly Vol. 26 No. 2, pp. xiii–xxiii. Verfügbar unter: https://web.njit.edu/~egan/Writing_A_Literature_Review.pdf, [Letzter Zugriff: 24 Mai 2022].
- Wittpahl, V. (2019): *Künstliche Intelligenz*, Berlin, Heidelberg, Springer Berlin Heidelberg. DOI: 10.1007/978-3-662-58042-4.
- Wuttke, L. (2022): *Praxisleitfaden für Künstliche Intelligenz in Marketing und Vertrieb*, Wiesbaden, Springer Fachmedien Wiesbaden. DOI: 10.1007/978-3-658-35626-2.