

Masterarbeit
im Masterstudiengang
Digital Leadership & IT-Management
an der Hochschule für angewandte Wissenschaften Neu-Ulm

**Einsatz und Potenziale Künstlicher Intelligenz im Bid Management: Eine Betrachtung
des Nutzen und der Herausforderungen der Implementierung von KI in den Proposal
Management Prozess.**

Erstkorrektor: Prof. Dr. Achim Dehnert

Zweitkorrektor: Prof. Dr. Klaus Lang

Verfasser: Sebastian Lippka (Matrikel-Nr.: 309901)

Thema erhalten: 09.12.2024

Arbeit abgegeben: 20.04.2025

Abstract

Künstliche Intelligenz (KI) ist spätestens seit Ende 2022 mit der Veröffentlichung von ChatGPT durch OpenAI in aller Munde. Dieser Meilenstein hat der breiten Öffentlichkeit gezeigt, wie weit KI, insbesondere Generative KI bereits entwickelt ist. Spätestens zu diesem Zeitpunkt ist klar geworden, dass KI den nächsten Schritt der Digitalisierung darstellt. Die Arbeit untersucht die Anwendungsmöglichkeiten von Künstlicher Intelligenz im Bid Management. Angesichts des zunehmenden Einsatzes von KI, insbesondere generativer Modelle, wird erforscht, wie diese Technologien den Angebotsprozess eines Unternehmens verbessern können. Nach einer Einführung in die verschiedenen KI-Techniken und einer Analyse typischer Einsatzbereiche wird das Bid Management vorgestellt, um Herausforderungen zu identifizieren, die durch KI unterstützt werden können. Es werden konkrete Anwendungsfälle aufgezeigt sowie Risiken bei der Implementierung von KI im Bid Management analysiert. Abschließend werden Empfehlungen gegeben, um Stolpersteine zu vermeiden und die Digitalisierung im Angebotsmanagement voranzutreiben.

Inhalt

Abstract.....	2
1 Einleitung	5
2 Grundlagen der Künstlichen Intelligenz	7
2.1 Definition	7
2.2 Unterschied zwischen schwacher KI und starker KI	9
2.3 Unterschied zwischen symbolischer KI und subsymbolischer KI	10
2.4 Arten von Künstlicher Intelligenz und ihre Anwendungsbereiche.....	10
2.4.1 Regelbasierte Systeme	11
2.4.2 Maschinelles Lernen	12
2.4.3 Deep Learning.....	17
2.4.4 Natural Language Processing	21
2.4.5 Robotic Process Automation	26
3 Grundlagen des Bid Managements	30
4 Zwischenfazit	32
5 Experteninterviews	34
5.1 Methodik der Experteninterview	34
5.2 Vorstellung der Experten.....	36
5.3 Ergebnisse aus den Interviews.....	37
5.4 Herausforderungen im Bid Management.....	40
6 Einsatzmöglichkeiten und Nutzen von KI im Bid Management	42
6.1 Reduzierung des Zeitaufwandes durch Robotic Process Automation.....	42
6.2 Vereinfachung der Anforderungsanalyse durch Natural Language Processing	43
6.3 Entlastung der Ressourcen durch maschinelles Lernen	44
6.4 Aufwandsreduzierung und Qualitätssicherung durch Generative Deep Learning ...	45
7 Herausforderungen und Risiken bei der Implementierung von KI im Bid Management..	48
7.1 Datenqualität und Datensicherheit.....	48
7.2 Erklärbarkeit und Transparenz von KI-Modellen.....	49
7.3 Technologische und organisatorische Anforderungen	51
7.4 Sonstige Risiken und Fehlerquellen	52
7.4.1 Abweichung zwischen Modellprognosen und realen Projektanforderungen	52
7.4.2 Fehlprognosen und mangelnde Validierung	53
7.4.3 Personelle und organisatorische Widerstände.....	54
7.4.4 Fehlendes Monitoring.....	55
8 Handlungsempfehlungen für die Implementierung von KI im Bid Management	57
8.1 Strategische Handlungsempfehlungen	58
8.2 Prozessuale Handlungsempfehlungen	59

8.3	Technologische Handlungsempfehlungen.....	61
8.4	Personelle Handlungsempfehlungen.....	62
9	Fazit.....	64
	Literatur.....	70
	Abbildungsverzeichnis.....	74
	Erklärung.....	75
	Abkürzungsverzeichnis.....	76

1 Einleitung

Die kontinuierliche Verbesserung von Prozessen ist ein wesentlicher Bestandteil unternehmerischen Erfolgs. Unternehmen, die ihre Abläufe nicht laufend optimieren, riskieren, ineffizient zu werden und gegenüber dem Wettbewerb ins Hintertreffen zu geraten (Laatupankki 2025). In den vergangenen Jahrzehnten hat insbesondere die Digitalisierung entscheidend dazu beigetragen, Ressourcen effizienter einzusetzen und Geschäftsprozesse effektiver zu gestalten (Forum Verlag Herkert GmbH 2019). Künstliche Intelligenz (KI) stellt in diesem Kontext die nächste Stufe der digitalen Transformation dar. Spätestens seit der Veröffentlichung von ChatGPT durch OpenAI Ende 2022 ist der Begriff einer breiten Öffentlichkeit bekannt. KI ermöglicht eine weitergehende Automatisierung, intelligente Datenanalysen und eröffnet neue Potenziale zur Effizienzsteigerung (Leder 2024).

Eine Branche, in der diese Entwicklungen von besonderer Bedeutung sind, ist das Bid Management. Dieser Bereich umfasst die Erstellung von Angeboten auf Ausschreibungen und Kundenanfragen und ist durch hohen Zeitdruck und hohe Qualitätsanforderungen geprägt. Die Integration von KI in diesen Prozess könnte sich als entscheidender Wettbewerbsvorteil erweisen (Brainial 2025). Systeme könnten historische Angebotsdaten analysieren, Trends erkennen und manuelle, repetitive Tätigkeiten automatisieren. Bid Manager könnten sich so stärker auf strategische Aufgaben fokussieren. Darüber hinaus ist der Einsatz von KI bei der automatisierten Beantwortung wiederkehrender Ausschreibungsfragen ein weiterer vielversprechender Anwendungsfall. Trotz dieser vielversprechenden Perspektiven bestehen Unsicherheiten: Welche Aufgaben im Bid Management eignen sich tatsächlich für den Einsatz von KI? Und wie sollte die Implementierung ausgestaltet werden, um nachhaltig Mehrwert zu schaffen?

Vor diesem Hintergrund verfolgt die Masterarbeit das Ziel, Möglichkeiten für die Implementierung von KI im Bid Management zu analysieren. Insbesondere wird untersucht, welche konkreten Aufgaben innerhalb des Bid Managements durch KI unterstützt und automatisiert werden können. Daraus ergibt sich die zentrale Forschungsfrage: *Welche Möglichkeiten gibt es, Künstliche Intelligenz im Bid Management zu implementieren, und welche Aufgaben können dabei durch KI im Angebotsprozess unterstützt oder übernommen werden?*

Um diese Forschungsfrage zu beantworten, stützt sich die Arbeit auf eine Kombination aus Literaturrecherche und Experteninterviews. Zunächst wird im zweiten und dritten Kapitel, durch eine Auswertung der Fachliteratur der aktuelle Wissensstand zur Künstlichen Intelligenz und zum Bid Management aufgearbeitet, um einen theoretischen Rahmen zu schaffen. Kapitel Vier zieht ein Zwischenfazit und bespricht die Ergebnisse der Literaturrecherche. Darauf aufbauend wird im fünften Kapitel zuerst die Methodik von Experteninterviews beschrieben. Die Experteninterviews werden anschließend zusammengefasst, um praxisrelevante Einblicke und Erfahrungswerte zu gewinnen, insbesondere zu den Herausforderungen, die sich im Bid Management ergeben. Im sechsten Kapitel werden die in Kapitel Fünf herausgearbeiteten Herausforderungen im Bid Management mit dem in Kapitel Zwei erarbeiteten Wissen zu KI zusammengebracht und Einsatzmöglichkeiten von KI im Bid Management vorgestellt. Die Herausforderungen und Risiken, die sich bei der Implementierung von KI im Bid Management ergeben werden durch die in den Interviews erwähnten Restriktionen und weiterer Literaturrecherche in Kapitel Sieben analysiert. Kapitel Acht leitet daraus Handlungsempfehlungen für die Implementierung ab. Beendet wird die Arbeit mit einem Fazit, das die Ergebnisse zusammenfasst, die Arbeit kritisch betrachtet und die Forschungsfrage beantwortet.

2 Grundlagen der Künstlichen Intelligenz

Um die vielfältigen Möglichkeiten der Nutzung von Künstlicher Intelligenz im Bid Management herzuleiten und eine theoretische Grundlage für die Beantwortung der Forschungsfrage zu schaffen, wird im folgenden Kapitel das Feld der Künstlichen Intelligenz analysiert und zusammengefasst. Zu Beginn wird sich einer Definition des Begriffes der Künstlichen Intelligenz angenähert. Anschließend erfolgt eine Unterscheidung zwischen starker und schwacher KI, um die unterschiedlichen Zielsetzungen und Fähigkeiten von KI-Systemen zu verdeutlichen. Darauf aufbauend wird die Differenzierung zwischen symbolischer und subsymbolischer KI dargestellt, die grundlegende Konzepte innerhalb der KI-Forschung beschreibt. Diese Strukturierung dient dazu, ein grundlegendes Verständnis der wesentlichen Konzepte und der verschiedenen Arten von KI zu vermitteln. Im darauffolgenden Kapitel werden die verschiedenen Arten von Künstlicher Intelligenz und ihre Anwendungsmöglichkeit erläutert. Diese bilden die Grundlage für die spätere Betrachtung von Implementierungsmöglichkeiten im Bid Management.

2.1 Definition

Der Begriff Künstliche Intelligenz (KI, im englischen AI – Artificial Intelligence) steht für das Teilgebiet der Informatik, das sich mit der Automatisierung intelligentem Verhaltens befasst, wurde durch den US-amerikanischen Informatiker John McCarthy geprägt, der diesen im Rahmen eines Förderantrag benutzte (McCarthy u. a. 2006). Er definierte den Begriff wie folgt (Ertel 2021, S. 1):

Ziel der KI ist es, Maschinen zu entwickeln, die sich verhalten, als verfügten sie über Intelligenz.

Diese Definition verdeutlicht, wie schwer es ist, den Begriff KI präzise zu fassen. Der Grund dafür liegt in der Komplexität des Begriffs „Intelligenz“ selbst, da es keine einheitliche Definition gibt, die alle Facetten menschlicher Intelligenz abdeckt. Allgemein lässt sich Intelligenz als die Fähigkeit definieren, Probleme zu lösen, zu lernen, und sich an neue Situationen anzupassen (Zweig 2023). In diesem Sinne ist KI der Versuch, diese menschlichen Fähigkeiten technisch zu imitieren, sodass Maschinen Aufgaben übernehmen können, die normalerweise die kognitiven Fähigkeiten des Menschen erfordern.

Die Europäische Union wiederum definiert ein KI-System im EU Artificial Intelligence Act auf folgende Weise, ohne das Wort Intelligenz zu benutzen:

Ein maschinengestütztes System, das so konzipiert ist, dass es mit unterschiedlichem Grad an Autonomie betrieben werden kann und nach seiner Einführung Anpassungsfähigkeit zeigt, und das für explizite oder implizite Ziele aus den Eingaben, die es erhält, ableitet, wie es Ausgaben wie Vorhersagen, Inhalte, Empfehlungen oder Entscheidungen generieren kann, die physische oder virtuelle Umgebungen beeinflussen können (Europäische Union 2025).

Diese Definition hebt besonders die Autonomie und die Anpassungsfähigkeit von KI-Systemen hervor sowie deren Fähigkeit, aus Daten Handlungsempfehlungen oder Entscheidungen abzuleiten, die reale oder virtuelle Umgebungen beeinflussen können.

Während der Auseinandersetzung mit der Thematik der Künstlichen Intelligenz fällt auf, dass es nicht nur zahlreiche Definitionen gibt, die den Begriff aus unterschiedlichen wissenschaftlichen, technischen und philosophischen Perspektiven beleuchten, sondern auch eine Vielzahl von Klassifizierungen in verschiedene Konzepte und Technologien. Dazu gehören Bereiche wie z. B. regelbasierte Systeme, Maschinelles Lernen, Deep Learning und Natural Language Processing, die in Abbildung 1 dargestellt sind. Diese bietet eine Übersicht über die Zuordnung der verschiedenen Arten von KI, wie sie in dieser Arbeit beschrieben werden.

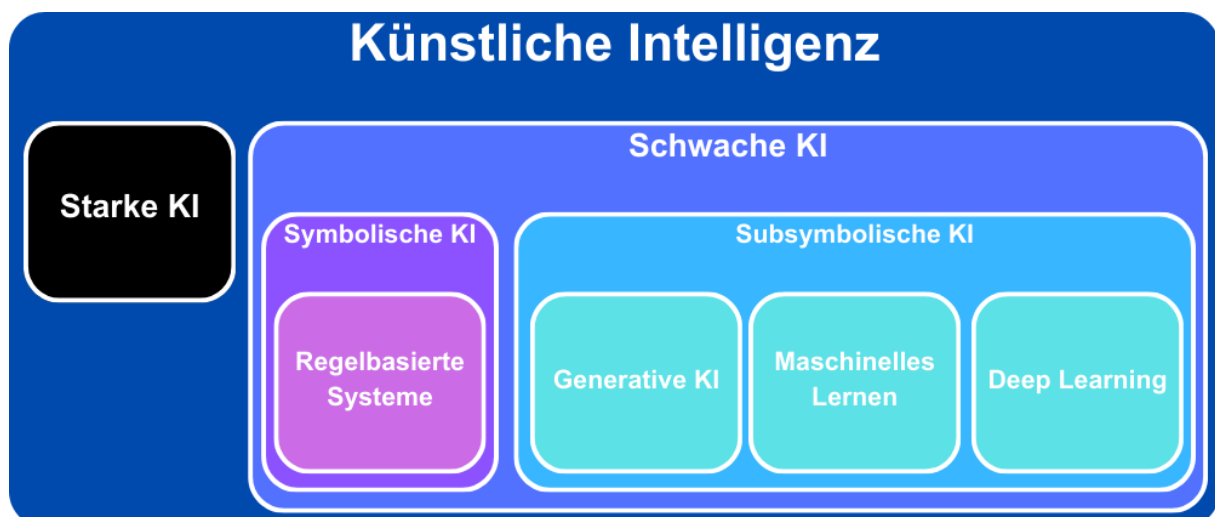


Abbildung 1: Klassifizierung Künstlicher Intelligenz (eigene Darstellung)

2.2 Unterschied zwischen schwacher KI und starker KI

Eine der wichtigsten Unterscheidungen im Bereich der Künstlichen Intelligenz ist die zwischen schwacher (eng. narrow) KI und starker (eng. general) KI, die im folgenden Kapitel näher erläutert wird. Diese Klassifizierung hilft, die Fähigkeiten der Technologie besser zu verstehen und einzuordnen (Institute of Data 2023).

Starke KI

Im Gegensatz dazu steht die starke KI, auch bekannt als künstliche allgemeine Intelligenz (Artificial General Intelligence, AGI). Eine starke KI soll in der Lage sein, menschenähnliches Denken und Verstehen zu erreichen, das sich nicht nur auf spezifische Aufgaben beschränkt, sondern auf breit angelegte kognitive Fähigkeiten übertragbar ist. Die Entwicklung von starker KI ist ein noch unerreichtes Ziel, das mit tiefgreifenden ethischen und technischen Herausforderungen verbunden ist

Schwache KI

Unter schwacher KI versteht man Systeme, die für spezifische Aufgaben programmiert wurden und über keine allgemeine Intelligenz verfügen. Diese Systeme sind auf bestimmte Anwendungsbereiche beschränkt und führen festgelegte Funktionen aus, wie z. B. Sprachassistenten, die Antworten auf festgelegte Fragen geben, oder Empfehlungsalgorithmen, die auf Nutzerdaten basieren. Ein prominentes Beispiel für schwache KI sind Chatbots oder automatisierte Kundensupportsysteme, die kontextbezogene Fragen beantworten können, aber nicht über allgemeine Problemlösungsfähigkeiten verfügen. Bisherige Fortschritte in der Forschung bewegen sich überwiegend im Bereich der schwachen KI, da starke KI eine tiefe Nachbildung der menschlichen Intelligenz erfordert. Diese Arbeit konzentriert sich daher in den folgenden Ausführungen auf Schwache KI.

2.3 Unterschied zwischen symbolischer KI und subsymbolischer KI

In der Praxis gibt es zwei wesentliche Ansätze zur Realisierung von schwacher KI: symbolische und subsymbolische KI. Deren Unterschiede werden im Folgendem beschrieben (Luber 2024).

Symbolische KI

Symbolische KI basiert auf expliziten Regeln, logischen Operationen und strukturierte Daten. In dieser Herangehensweise wird Wissen durch Symbole und logische Verknüpfungen dargestellt, die es dem System ermöglichen Entscheidungen zu treffen und Probleme zu lösen. Symbolische KI wird oft als regelbasierte KI bezeichnet, da ihre Entscheidungsfindung auf formalen Regeln und logischen Bedingungen beruht. Die Entwicklung symbolischer KI dominierte die frühen Jahre der KI-Forschung und legte den Grundstein für Expertensysteme und regelbasierte Entscheidungsunterstützungssysteme. Regelbasierte Systeme werden im Kapitel 2.4.1 genauer beschrieben.

Subsymbolische KI

Subsymbolische KI wird auch statistische KI bezeichnet und basiert auf datengetriebenen, statistischen Methoden. Anstatt Regeln und Symbole zu verwenden, lernt subsymbolische Muster und Zusammenhänge aus großen Datenmengen und passt ihre Vorhersagen und Entscheidungen auf Basis dieser Daten an.

Im Vergleich zu symbolischer KI ist diese oft einfacher zu erklären, da die statistischen Systeme subsymbolischer KI nicht mehr nachvollziehbar sind.

2.4 Arten von Künstlicher Intelligenz und ihre Anwendungsbereiche

Im Kontext der modernen Künstlichen Intelligenz existieren mehrere Ansätze und Technologien, die für unterschiedliche Aufgaben und Anwendungsfälle genutzt werden. Die wesentlichen Arten der KI lassen sich in regelbasierte Systeme, maschinelles Lernen (ML), Deep Learning (DL), Natural Language Processing (NLP) und Robotic Process Automation (RPA) unterteilen. Im Folgenden werden diese Arten und deren Anwendungsbereiche beschrieben, um im späteren Verlauf der Arbeit potenzielle Nutzungsmöglichkeiten im Bid Management abzuleiten.

2.4.1 Regelbasierte Systeme

Regelbasierte Systeme sind eine der frühesten Formen der Künstlichen Intelligenz und eine Art von Expertensystem. Sie basieren auf der Implementierung von explizierten Regeln und Logiken zur Steuerung von Entscheidungen. Diese Systeme arbeiten nach dem Prinzip der „Wenn-Dann-Regeln“, welche fest definierte Bedingungen und entsprechende Aktionen formulieren. Sie sind besonders dann nützlich, wenn die Entscheidungsparameter bekannt und eindeutig sind. Dadurch finden sie in den Bereichen Anwendung, in denen keine komplexen Lernprozesse erforderlich sind und die Daten in vorhersehbare Muster fallen (Beierle/Kern-Isberner 2019, S. 73 f).

Funktionsweise regelbasierter Systeme

Für Gewöhnlich bestehen regelbasierte Systeme aus einer Wissensbasis und einer Inferenz Maschine. Die Wissensbasis eines regelbasierten Systems speichert die Objekte und Regeln, die im System für die Entscheidungsfindung erforderlich sind. Diese bilden das abstrakte Wissen der Wissensbasis. Das konkrete Wissen einer Wissensbasis bilden Beobachtungen und Befunde über den speziellen Einsatzfall, wie z. B. Anforderungen und Standards. Die Wissensbasis wird von Experten definiert (Beierle/Kern-Isberner 2019, S. 77 f).

Die Inferenzmaschine ist ein Regelnetzwerk und wendet die verschiedenen Inferenzregeln auf die Fakten der Wissensbasis an. Sie vergleicht dafür die gespeicherten Regeln mit den gegebenen Daten und leitet daraus Entscheidungen ab. Hierzu werden verschiedene Ansätze genutzt. Zum einen die datengetriebene Inferenz (Vorwärtsverkettung) zum anderen die zielorientierte Inferenz (Rückwärtsverkettung). Die Vorwärtsverkettete Inferenz arbeitet sich schrittweise durch die Regeln, um neue Informationen abzuleiten. Es werden immer die Regeln angewendet, die durch die neuen Fakten ausgelöst werden, um die Schlussfolgerung dann als neuen Fakt hinzuzufügen. Die Kette endet, wenn keine Regeln mehr angewendet werden können. Vorwärtsverkettung eignet sich dadurch besonders gut für Fälle, in denen alle Eingabefakten bekannt sind und das Ziel darin besteht eine umfassende Schlussfolgerung aus diesen Fakten zu ziehen. Bei der Rückwärtsverkettung arbeitet das System mit einer Hypothese und prüft, welche Fakten und Regeln dieses Ziel erreichen. Anschließend wird versucht die Voraussetzungen, durch das Vorarbeiten zu den erforderlichen Eingabefakten, zu erfüllen. Die Rückwärtsverkettung ist besonders dann nützlich, wenn man eine Hypothese oder ein spezifisches Ziel, dass man erreichen möchte, überprüft. Sie wird daher

häufig in Diagnose- und Entscheidungsfindungssystemen eingesetzt (Beierle/Kern-Isberner 2019, S. 80 ff).

Vorteile und Einschränkungen regelbasierter Systeme

Der Vorteil regelbasierter Systeme liegt in ihrer Transparenz und Erklärbarkeit. Durch die explizit definierte Entscheidungslogik können Benutzer leicht nachvollziehen, warum eine bestimmte Entscheidung getroffen wurde (Faster Capital 2025).

Auf der anderen Seite können regelbasierte Systeme nur begrenzt mit Unsicherheiten und unvorhergesehenen Situationen umgehen, da sie nur auf den festgelegten Regeln basieren und keine Lernfähigkeit besitzen. Das macht sie auch im Vergleich zum maschinellen Lernen weniger flexibel und skalierbar (Faster Capital 2024).

Anwendungsbereiche regelbasierter Systeme

Regelbasierte Systeme sind vielseitig einsetzbar, besonders in Systemen, die von klar definierten Regeln und strukturierten Entscheidungsprozessen profitieren. Ein Beispiel ist das Diagnosesystem MYCIN, ein regelbasiertes Expertensystem, um Infektionskrankheiten zu diagnostizieren und Behandlungsvorschläge zu erstellen (Beierle/Kern-Isberner 2019, S. 91 f). Die Wissensbasis bestand in diesem Beispiel aus einer Sammlung von etwa 600 „Wenn-Dann-Regeln“, die von medizinischen Experten festgelegt wurden. Diese Regeln codierten spezifisches medizinisches Wissen. Weitere Anwendungsbereiche sind beispielsweise Kreditrisikobewertung anhand vordefinierter Kriterien wie Einkommen und Kreditgeschichte, Anti-Geldwäsche-Bekämpfung durch die Analyse von Transaktionen und regelbasierte Chatbots zur Beantwortung von FAQs.

2.4.2 Maschinelles Lernen

Maschinelles Lernen (ML) als Teilbereich der Künstlichen Intelligenz beschäftigt sich mit der Entwicklung von Algorithmen und Modellen, durch die Computer aus Daten lernen und darauf basierend Entscheidungen zu treffen, ohne explizit programmiert zu sein, wie es bei regelbasierten Systemen der Fall ist. Der Prozess ist adaptiv und lernt kontinuierlich aus Erfahrungen und neuen Daten. Systeme lernen so eigenständig aus großen Datenmengen ohne eine vorausgehende vollständige regelbasierte Modellierung. Dadurch ist es möglich, komplexe Zusammenhänge und Abhängigkeiten in Daten zu erkennen, die ansonsten auf traditionelle statistische Art und Weise schwer zu erfassen wären (Wuttke 2024).

Methoden des Maschinellen Lernens

Im maschinellen Lernen wird eine Vielzahl von Methoden, je nach Ziel und Daten Art, verwendet. Diese lassen sich in drei Hauptkategorien unterteilen: überwachtes Lernen, unüberwachtes Lernen und bestärktes Lernen (Jung 2024, S. 14).

Überwachtes Lernen (Supervised Learning): Beim überwachten Lernen wird das Modell mit einem Datensatz trainiert, der sowohl Eingabe- als auch Ausgabevariablen enthält. Ziel ist es, eine Funktion zu lernen, die eine Beziehung zwischen den Eingaben (Features) und den Ausgaben (Labels) beschreibt (Jung 2024, S. 115 f). Häufig verwendete Algorithmen des überwachten Lernens sind z. B:

- Lineare Regression: Dieser einfachere Algorithmus dient dazu, numerische Werte vorherzusagen, indem er eine lineare Beziehung zwischen verschiedenen Variablen herstellt (IBM 2024).
- Entscheidungsbäume: Entscheidungsbäume eignen sich sowohl für die Vorhersage numerischer Werte (Regression) als auch für die Einteilung von Daten in verschiedene Kategorien (Klassifikation). Sie basieren auf einer Reihe verzweigter und verknüpfter Entscheidungen, die als Baumdiagramm visualisiert werden können (IBM 2024).
- Random Forests: Ein Random Forest ist ein Algorithmus des maschinellen Lernens, der einen Wert oder eine Kategorie vorhersagt, indem er die Ergebnisse mehrerer Entscheidungsbäume zusammenführt (IBM 2024).
- k -Nearest-Neighbor: Der k -Nearest-Neighbor-Algorithmus (kurz k -NN) ist ein Verfahren des maschinellen Lernens, das Vorhersagen trifft, indem es die Ähnlichkeiten zu den k nächsten Nachbarn eines Datenpunkts analysiert. k ist dabei eine ganze, positive Zahl. Zur Vorhersage eines Wertes oder einer Kategorie betrachtet der Algorithmus die k ähnlichsten Datenpunkte im Datensatz und gibt basierend auf deren Eigenschaften eine Schätzung ab (Goodfellow/Bengio/Courville 2018, S. 158 f).

Unüberwachtes Lernen (Unsupervised Learning): Im Unterschied zum überwachten Lernen arbeitet das Modell beim unüberwachten Lernen nur mit Eingabedaten ohne vordefinierte Labels. Das Ziel ist es, versteckte Muster oder Strukturen in Daten zu identifizieren. Zu den gängigen Algorithmen des unüberwachten Lernen zählen z. B. (Goodfellow/Bengio/Courville 2018, S. 115 f):

- **k-Means-Clustering:** Dieser spezielle Algorithmus der Clusteranalyse ermöglicht es Datenpunkte in Gruppen (sog. Cluster) zu unterteilen, die sich in ihren Eigenschaften ähneln. Der Algorithmus gruppiert die Daten, indem er zunächst zufällige Clusterzentren festlegt und die Datenpunkte anhand der kürzesten Distanz diesen Zentren zuordnet. Danach werden die Clusterzentren iterativ dadurch angepasst, dass sie an den Durchschnittspunkt der zugehörigen Datenpunkte verschoben werden. Dieser Prozess wird wiederholt, bis die Clusterzentren stabil sind. Dadurch können Muster in den Daten erkannt werden, ohne dass vorherige Labels oder Klassifizierungen notwendig sind. Er eignet sich zur Entdeckung verborgener Strukturen in unbeschrifteten Daten (Goodfellow/Bengio/Courville 2018, S. 165 f), (IBM 2024).
- **Principal Component Analysis (Hauptkomponentenanalyse):** Die PCA ist ein Verfahren zur Reduktion der Dimensionalität von Datensätzen. Sie dient dazu, die wichtigsten Merkmale eines Datensatzes zu extrahieren, indem sie die ursprünglichen Variablen in sogenannte Hauptkomponenten umwandelt. Diese Hauptkomponenten erfassen den größten Teil der Variabilität im Datensatz und reduzieren so dessen Komplexität, ohne wesentliche Informationen zu verlieren. PCA wird häufig eingesetzt, um große Datensätze übersichtlicher zu machen und die Effizienz anderer Algorithmen zu verbessern, insbesondere bei Daten mit vielen Variablen (Goodfellow/Bengio/Courville 2018, S. 163).

Bestärkendes Lernen (Reinforcement Learning): Hier interagieren Algorithmen mit einer Umgebung und es kommt zu einer Feedbackschleife, um durch Versuch und Irrtum die Aktionen zu optimieren (Goodfellow/Bengio/Courville 2018, S. S. 116). Abbildung 4 zeigt den grundlegenden Ablauf des bestärkenden Lernens. Er stellt die Interaktion eines Agenten mit seiner Umgebung (Environment) dar und beschreibt, wie der Agent lernt, durch Aktionen optimale Entscheidungen zu treffen. Der Zustand (State) S_t beschreibt die aktuelle Situation, in der sich der Agent befindet. Zu jedem Zeitpunkt t befindet sich der Agent in einem bestimmten Zustand in seiner Umgebung. Basierend auf dem aktuellen Zustand S_t wählt der Agent eine Aktion A_t , die er ausführen möchte. Diese Aktion beeinflusst den Übergang zu einem neuen Zustand in der Umgebung. Die Auswahl der Aktion erfolgt durch eine Entscheidungsstrategie (Policy), die darauf abzielt, die Belohnung zu maximieren. Die Umgebung ist das System, mit dem der Agent interagiert. Sie reagiert auf die Aktionen des Agenten und gibt dem

Agenten eine Rückmeldung in Form einer Belohnung sowie eines neuen Zustands. Die Umgebung bestimmt, wie die Aktionen des Agenten das System beeinflussen und welche Belohnungen (Rewards) daraus resultieren. Nachdem der Agent die Aktion A_t im Zustand S_t ausgeführt hat, erhält er eine Belohnung R_t von der Umgebung. Diese



Abbildung 2: Schematische Darstellung von Reinforcement Learning (eigene Darstellung)

Belohnung gibt an, wie gut oder schlecht die Aktion des Agenten in Bezug auf das Erreichen eines Ziels war. Durch die Aktion A_t wechselt der Agent in einen neuen Zustand S_{t+1} . Der Agent erhält also nicht nur eine Belohnung, sondern auch Informationen über den neuen Zustand, in dem er sich nun befindet. Dieser neue Zustand beeinflusst die zukünftigen Entscheidungen des Agenten, da er seine Strategie anpassen kann. Die verschiedenen Aktionen und Zustände werden in der sogenannten Q-Table gespeichert. Durch die wiederholte Interaktion mit der Umgebung lernt der Agent die beste Strategie zu finden, um die kumulierte Belohnung zu maximieren. Dazu passt er sein Verhalten an und optimiert seine Aktionen basierend auf der erhaltenen Belohnung (Ertel 2021, S. 363 ff).

Zum Einsatz kommen beim bestärkenden Lernen beispielsweise folgende Algorithmen:

- Q-Learning: Der Q-Learning Algorithmus ist eine modellfreie Methode des bestärkenden Lernens, die es dem Agenten ermöglicht, eine optimale Strategie zu lernen, um langfristige Belohnungen in einer gegebenen Umgebung zu maximieren. Der Algorithmus ist besonders in Situationen nützlich, in denen die Dynamik der Umgebung nicht bekannt ist. Modellfrei wird ein Algorithmus dann genannt, wenn er kein explizites Modell der Umgebung benötigt, um zu

lernen. Ein modellfreier Algorithmus lernt stattdessen direkt aus der Interaktion der Umgebung, indem er Zustände, Aktionen, Belohnungen und resultierende Zustandsübergänge beobachtet. Dieser Vorteil macht Q-Learning flexibel einsetzbar. Außerdem konvergiert der Algorithmus zur optimalen Q-Funktion, was ihn sehr robust und zuverlässig macht. Nachteil des Q-Learnings ist die mangelnde Skalierbarkeit. Bei großen Zustands- und Aktionsräumen steigt der Speicherbedarf und die Rechenzeit exponentiell, weshalb er für diese Fälle ungeeignet ist (Ertel 2021, S. 374).

- Deep Q-Networks (DQN): Diese sind eine Erweiterung des Q-Learning-Algorithmus, die dessen Einschränkungen, insbesondere in komplexen Umgebungen mit großen Zustands- und Aktionsräumen überwinden. Anstatt einer expliziten Q-Tabelle werden künstliche neuronale Netze verwendet, um die Q-Funktion zu approximieren. Damit sind Deep Q-Networks ein Schnittpunkt zur spezifischen Unterkategorie des maschinellen Lernens, dem Deep Learning. Durch die Implementierung der künstlichen neuronalen Netze, können DQNs mit sehr großen, Zustandsräumen umgehen, was sie geeigneter für komplexe Probleme macht. Dagegen steht die erhöhte Rechenintensität. Außerdem ist eine sorgfältige Abstimmung der Parameter wie der Lernrate und die Architektur des neuronalen Netzwerkes unabdingbar, um gute Ergebnisse zu erzielen. Bei schlecht gewählter Abstimmung der sogenannten Hyperparameter kann es zu Instabilitäten beim Lernen kommen (Simonini 2025).

Vorteile und Einschränkungen des maschinellen Lernens

Im Vergleich zu regelbasierten Systemen sind ML-Modelle durch ihre Lernfähigkeit flexibler. Sie können sich dynamisch an neue Daten anpassen, ohne dass neue explizite Regeln programmiert werden müssen. Ein weiterer Vorteil ist die vorhandene Erklärbarkeit. Die Nachvollziehbarkeit der Entscheidungen ist nicht so einfach wie bei regelbasierten Systemen, jedoch wesentlich einfacher als beim Deep Learning, bei dem man bereits von einer Black Box Thematik spricht. Diese wird im Kapitel 2.4.3 genauer erläutert. Ebenso braucht ML weniger Rechenaufwand als DL-Methoden, was es effizienter und günstiger macht. Die Einschränkungen des maschinellen Lernens liegen bei komplexen Mustern, unstrukturierten Daten und großen Datensätzen. Hier zeigt sich Deep Learning wesentlich genauer und effizienter als ML. Damit bietet maschinelles Lernen einen Kompromiss zwischen den starren regelbasierten Systemen

und dem hochleistungsfähigen, aber rechenleistungsintensiven Deep Learning (Nikhil 2024).

Anwendungsbereiche des Maschinellen Lernens

Maschinelles Lernen hat vielfältige Anwendungsbereiche. Zentrale Anwendungsbereiche des maschinellen Lernens sind die Datenanalyse und die Prognose. In der Wirtschaft wird ML häufig eingesetzt, um große Datenmengen zu analysieren und daraus Vorhersagen abzuleiten. Beispielsweise verwenden Finanzinstitute maschinelles Lernen zur Betrugserkennung, indem sie Transaktionsmuster analysieren und ungewöhnliche Aktivitäten in Echtzeit identifizieren. Des Weiteren wird ML im Marketing genutzt, um das Verhalten von Kunden vorherzusagen, personalisierte Empfehlungen zu geben und so die sogenannte Conversion-Rate (die Anzahl an gewünschten Aktionen auf einer Webseite pro Besucher) zu erhöhen. Empfehlungsalgorithmen, wie sie von Netflix oder Amazon eingesetzt werden, basieren auf maschinellen Lernmodellen, die das Konsumverhalten der Nutzer analysieren und ähnliche Inhalte vorschlagen. Ein weiteres wichtiges Einsatzgebiet ist das Gesundheitswesen, wo ML zur Diagnose von Krankheiten, zur Analyse medizinischer Bilder und zur personalisierten Medizin beiträgt. Maschinelles Lernen kann Muster in medizinischen Daten erkennen, die für den Menschen schwer erkennbar sind, und so z. B. bei der Früherkennung von Krebs oder der Vorhersage von Krankheitsverläufen unterstützen. Auch in der pharmazeutischen Forschung wird ML eingesetzt, um die Entwicklung neuer Medikamente zu beschleunigen, indem es hilft, potenzielle Wirkstoffe schneller zu identifizieren. (SRH Fernhochschule 2025b)

2.4.3 Deep Learning

Deep Learning stellt eine spezialisierte Form des Maschinellen Lernens dar, durch die komplexen Muster und Strukturen in großen Mengen unstrukturierter Daten erkennbar werden. Die Basis dafür bilden künstliche neuronale Netze, die die Arbeitsweise des menschlichen Gehirns als Vorbild haben. Durch die hohe Effektivität darin, tief verschachtelte Merkmalsdarstellungen aus den Daten zu extrahieren, ist Deep Learning in der Lage sehr komplexe Aufgaben wie die Bild- und Spracherkennung zu bewältigen. Vom traditionellen Maschine Learning Methoden unterscheidet sich Deep Learning darin, dass die Merkmale nicht manuell ausgewählt werden müssen, sondern automatisiert extrahiert werden (Matzka 2021, S. 5 f).

Funktionsweise von Deep Learning

Die Funktionsweise von Deep Learning Systemen basiert auf Künstlichen Neuronalen Netzen (Artificial Neural Networks, ANN). Diese Netze bestehen aus einer Eingangsschicht (Input Layer), einer (einschichtige ANN) oder mehreren (mehrschichtige ANN) verborgenen Schichten (Hidden Layer) und einer Ausgangsschicht (Output Layer). Abbildung 3 stellt ein Neuronales Netz schematisch dar.




Abbildung 3: Schemenhafte Darstellung eines Neuronales Netzes (IBM 2021b)

Die Eingabeschicht nimmt Rohdaten aus der Umgebung oder einem Datensatz entgegen. Alle Daten werden dabei als numerischer Wert dargestellt, jede Eigenschaft des Inputs entspricht einem Neuron. In den Hidden Layers findet die eigentliche Datenverarbeitung statt. Die Eingaben werden gewichtet, aufsummiert und durch Aktivierungsfunktionen transformiert. Je mehr Hidden Layers vorhanden sind, desto komplexer kann das Neuronale Netz lernen. Jedes Neuron, also jeder aktive Knotenpunkt innerhalb der Hidden Layer ist mit Neuronen der vorherigen und der nächsten Schicht verbunden. Die Ausgabeschicht gibt das Ergebnis des Netzes aus, das kann eine Klassifizierung oder eine Vorhersage sein. Die Anzahl der Neuronen in dieser Schicht hängt von der Aufgabe ab (z. B. zwei Neuronen für Ja und Nein). Die Funktionsweise eines Neuronales Netzwerkes ist wie folgt: Zunächst werden die Eingabedaten als numerische Werte in das Netzwerk eingespeist. Beispielsweise werden bei Bildern jedem Pixel eines in Graustufen dargestellten Bildes ein Zahlenwert von 0 bis 255 zugeordnet. Anschließend finden die Gewichtung und Berechnung der Aktivierung statt. Die Verbin-

dungen zwischen den Neuronen tragen Gewichte (Weights), die die Stärke der Verbindung bestimmen. Jedes Eingabeneuron multipliziert seinen Wert mit dem zugehörigen Gewicht und sendet das Ergebnis an die Neuronen der nächsten Schicht. Alle gewichteten Eingaben eines Neurons werden aufsummiert und zusätzlich mit einem sogenannten Bias-Wert addiert um die Aktivierung flexibel zu verschieben. Die Summe der gewichteten Eingaben wird durch eine Aktivierungsfunktion transformiert, um zu bestimmen, ob ein Neuron aktiviert wird. An dieser Stelle werden die Funktionen nicht-linear, um dem Netzwerk das Lernen komplexer Muster zu ermöglichen. Gängige Aktivierungsfunktionen sind beispielsweise die Sigmoid Funktion zum Komprimieren von Werten in dem Bereich von 0 bis 1, um Wahrscheinlichkeiten zu ermitteln, oder die Rectified Linear Unit, die nur positive Werte ausgibt und negative Werte auf 0 setzt. Anschließend werden die aktivierten Werte in die nächste Schicht weitergegeben. Dieser Schritt wird für alle Hidden Layers wiederholt, bis die Ausgabeschicht das endgültige Ergebnis liefert. Der nächste Schritt ist die Fehlerberechnung. Eine Fehlerfunktion (Loss Function) misst, wie weit die Vorhersage vom richtigen Ergebnis abweicht, indem das Ergebnis des Netzwerks mit dem tatsächlichen Zielwert verglichen wird. Gängigen Fehlerfunktionen sind der Mean Squared Error für Regressionsaufgaben und der Cross-Entropy Loss für Klassifikationsaufgaben. Für das tatsächliche Lernen wird der Fehler durch das Netzwerk zurückgeführt (Backpropagation) um die Gewichte zu korrigieren. Durch das Gradientenabstiegsverfahren wird der steilste Abstieg der Fehlerfunktion bestimmt in dessen Richtung die Gewichte angepasst werden. Der Fehler wird somit in der nächsten Iteration kleiner. Dieser Prozess wird so lange wiederholt, bis der Fehler minimal wird (Matzka 2021, S. 114 ff).

Eine weitere Art von neuronalen Netzen sind die Convolutional Neural Networks (CNN). CNNs sind speziell für die Verarbeitung von Bilddaten entwickelt worden. Sie nutzen Faltungsoperationen, um räumliche Merkmale in Bildern zu extrahieren, und sind in der Lage, visuelle Muster in großem Maßstab zu erkennen. CNNs haben sich als besonders leistungsfähig bei Aufgaben wie der Bilderkennung und -klassifikation erwiesen (Goodfellow/Bengio/Courville 2018, S. 369).

Anwendungsbereiche des Deep Learning

Da Deep Learning ein Werkzeug für Problemlösungen in der Datenverarbeitung ist, gibt es unterschiedlichste Anwendungsfälle. Ein anschauliches Beispiel sind selbstfahrende Autos. Moderne Autos sammeln große Mengen an Daten aus Sensoren und Kameras, welche DL nutzt, sodass das Auto die richtige Entscheidung zu treffen kann. Ein weiteres Beispiel ist die Spracherkennung wie sie bei Siri oder Alexa zum Einsatz kommt. Hierfür werden ANNs verwendet, um diesen Programmen zu ermöglichen, die menschliche Sprache zu „verstehen“. Für den Einsatz in Unternehmen haben sich bereits verschiedene Frameworks etabliert, um die verschiedensten Anwendungsfälle zu bearbeiten. Hierzu gehört zum einen das *Python* und *C++* basierte Open-Source Framework *TensorFlow*, das bereits für Google Suche, Google Fotos und die Google Spracherkennung verwendet wird. Große KI-Forschungs- und Entwicklungsteams wie die von *Facebook* und *OpenAI* setzen hingegen auf das Open-Source Framework *PyTorch* (Wuttke 2023).

Vorteile und Einschränkungen des Deep Learning

DL hat mehrere, bereits erwähnte Vorteile, welche im Detail erläutert werden. Durch die automatische Merkmalsextraktion erkennen die Modelle selbständig, welche Merkmale in den Daten wichtig sind, ohne dass sie manuell definiert werden müssen. Das führt dazu, dass Deep Learning herorragend mit unstrukturierten Daten wie Bildern und Texten arbeiten kann. Des Weiteren skalieren sie besonders gut. Je größer die Datenmenge, die zum Trainieren vorhanden ist, desto besser wird die Leistung der DL-Modelle. Besonders bei komplexen Aufgaben besitzen sie somit eine höhere Genauigkeit. Diese Vorteile machen Deep Learning besonders vielseitig in der Anwendung (Nikhil 2024).

Neben vielen Vorteilen hat Deep Learning auch einige Nachteile, die durch die Komplexität der Modelle entstehen. Die große Menge an Trainingsdaten, die benötigt wird, um genaue Vorhersagen zu treffen, ist nicht für jeden potenziellen Anwendungsfall verfügbar. Bereiche mit begrenzten Daten können daher weniger von Deep Learning profitieren. Die Komplexität wirkt sich auch auf den Rechenaufwand und damit auf den Energieverbrauch aus. So investieren mittlerweile große Tech-Unternehmen wie Amazon und Oracle in die Forschung von kleinen modularen Atomkraftwerken, um den enormen Energieverbrauch ihrer Rechenzentren zu decken (Deutschlandfunk 2024).

Eine der größten Herausforderungen, die mit Deep Learning einhergeht, ist die bereits erwähnte Black-Box-Problematik. Durch die Komplexität der Deep Learning Modelle sind diese nur schwer bis gar nicht nachvollziehbar. Dies führt dazu, dass obwohl diese Modelle meistens sehr genaue Vorhersagen oder Entscheidungen treffen, unklar bleibt, wie und warum die Modelle zu diesem Ergebnis kommen. Die internen Berechnungen und Entscheidungsprozesse sind auf Grund der sehr hohen Anzahl von Gewichten und Aktivierungsfunktionen nicht direkt nachzuvollziehen und selbst die Entwickler verstehen oft nicht, welche Merkmale ein Modell gelernt hat. Besonders bei kritischen Entscheidungen, z. B. in Bereichen wie Medizin, Finanzen oder der Justiz ist es wichtig, zu wissen, warum eine Entscheidung so getroffen wurde. Unklare, beziehungsweise unverständlichen Entscheidungsprozesse wird nicht das nötige Vertrauen geschenkt, um kritische Entscheidungen, die durch sie getroffen wurden, zu akzeptieren. Des Weiteren sind Erklärbarkeit und Transparenz in regulierten Branchen gesetzlich vorgeschrieben (Selbst/Powles 2017). Die Black-Box-Problematik kann unter Umständen so weit führen, dass Modelle durch verzerrte Trainingsdaten falsche oder diskriminierende Entscheidungen treffen, die nicht erkannt werden. Eine mögliche Methode, um Deep Learning erklärbarer zu machen, ist die Visualisierung von Daten beispielsweise das Sichtbarmachen der Bildbereiche, die in der Bilderkennung für die Entscheidung genutzt werden (Blouin 2023).

2.4.4 Natural Language Processing

Natural Language Processing wird im Deutschen als Computerlinguistik bezeichnet. Das Themenfeld beschäftigt sich mit der Interaktion zwischen Computern und der natürlichen, menschlichen Sprache. NLP umfasst Algorithmen, die entwickelt wurden, um Texte und Sprache zu verstehen, zu interpretieren und zu generieren (IBM 2021a). Es gibt verschiedene Systeme, um NLP zu erreichen. Diese werden im Folgenden erklärt.

Systeme des Natural Language Processing

Die Arten Mechaniken von NLP sind vergleichbar mit den Grundarten von KI. Zu ihnen gehören regelbasierte Systeme, statistische Modelle, auf maschinellem Lernen basierte Systeme und auf Deep Learning basierte Systeme.

Regelbasierte Systeme (Rule-Based NLP) verwenden explizite linguistische Regeln, die von Experten definiert werden. Dies sind oft einfache „Wenn-Dann-Regeln“ zur

grammatikalischen Analyse. Das macht sie starr und schwer skalierbar, weshalb sie hauptsächlich für Grammatikprüfungen oder einfache Textanalysen verwendet werden (IBM 2021a).

Die Statistical NLP, bzw. statistische Computerlinguistik verwendet mathematische und stochastische Modelle, um Wahrscheinlichkeiten von Wortfolgen oder Zusammenhänge zwischen Wörtern zu berechnen. Verwendet wurden solche Modelle beispielsweise für die Übersetzungssysteme wie das frühere Google Translate oder die Autovervollständigung bei Suchmaschinen. Häufige Methoden statistischer Computerlinguistik sind n -Gramme und sogenannte Hidden Markov Models. Hierfür werden allerdings große Datenmengen benötigt und eine semantische Beziehung ist innerhalb der Vorhersagen nicht erfassbar (Jurafsky/Martin 2025, S. 34 ff).

Auf maschinellem Lernen basierende Systeme nutzen im Gegensatz zu auf Deep Learning basierenden Ansätzen, manuell erstellte Merkmale zur Analyse von Texten. Sie werden verwendet, um Texte zu klassifizieren und ähnliche Dokumente zu gruppieren. Ein Beispiel hierfür ist das Erkennen von Spam-Mails. Zur Anwendung kommen bereits bekannte, klassische ML-Algorithmen, wie Naive Bayes und k -Means-Clustering (Jurafsky/Martin 2025, S. 56 ff).

Die Methodik, um die es in diesem Kapitel hauptsächlich gehen soll, sind Deep Learning basierte NLP-Systeme. Diese sind spätestens seit dem Aufkommen von Large Language Modells (LLMs) wie ChatGPT in aller Munde und haben damit die Computer Linguistik revolutioniert. Deep Learning ermöglicht es Sprachdaten effektiver zu analysieren, kontextuelle Zusammenhänge besser zu verstehen und leistungsstarke Anwendungen, z. B. Sprachassistenten oder Übersetzungsmaschinen zu entwickeln. Die generelle Vorgehensweise von Deep Learning ist bereits im Kapitel 2.4.3 beschrieben.

Ein zentrales Konzept im Bereich des NLP sind Word Embeddings (Worteinbettungen), welche für das Verständnis der Funktionsweise von Deep Learning basierten NLPs, wie LLMs grundlegend sind. Durch Embeddings werden Wörter, Sätze oder andere sprachliche Einheiten in numerische, hochdimensionale Vektoren überführt. Dadurch werden durch Maschinen lesbare Darstellungen erzeugt, die semantische und syntaktische Informationen enthalten. Hierzu werden Wörter oder Sätze in jeweils einzelne Vektoren gewandelt. Diese Vektoren repräsentieren die sprachlichen Einheiten in einem kontinuierlichen, dichten Raum, in dem ähnliche Wörter nahe beieinander

liegen, während unähnliche Wörter weiter voneinander entfernt sind. Dies geschieht durch das Trainieren von Modellen mittels großer Datenmengen an Texten, wobei die Modelle lernen, kontextuelle und semantische Beziehungen zwischen Wörtern durch die Minimierung des Fehlers, der die Ähnlichkeit zwischen Wörtern und ihrem Kontext maximiert, zu erfassen. Mathematisch spricht man von einer Kosinus-Ähnlichkeit. Die wird durch den Winkel zwischen zweien Vektoren berechnet und liegt zwischen -1 und 1, wobei sich Vektoren mit einem Kosinus von ca. 1 in der Bedeutung sehr ähneln und die Bedeutung von Vektoren mit einem Kosinus von ca. 0 sehr unähnlich ist. Ein Kosinus von -1 deutet auf eine gegenteilige Bedeutung hin. Da der Kontext von Wörtern erhalten bleibt, können auch gleiche Wörter mit unterschiedlichen Bedeutungen dargestellt werden (Pangeanic 2024).

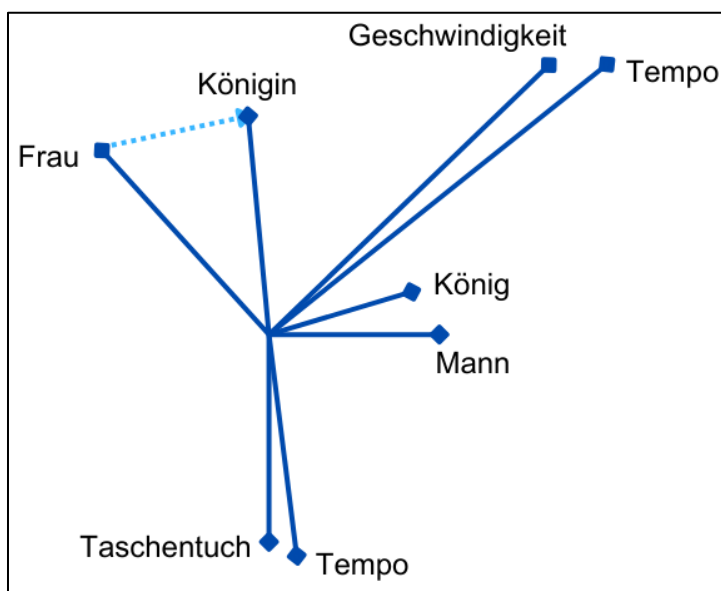


Abbildung 4: Schematische Darstellung für Word-Embeddings (eigene Darstellung)

Abbildung 4 zeigt vereinfacht, wie Embeddings funktionieren. Zur Veranschaulichung werden in dieser Abbildung nur zwei-dimensionale Vektoren verwendet. In der Realität werden hochdimensionale Vektoren verwendet. Die Vektoren „Geschwindigkeit“ und „Tempo“ sind sehr nah beieinander, wohingegen der Vektor „Frau“ weiter davon entfernt ist. Das Wort „Tempo“ kann ebenso der Markenname eines Taschentuchs sein, weshalb es einen weiteren Eintrag von „Tempo“ in der Nähe zum Vektor „Taschentuch“ gibt.

Ein weiterer Vorteil dieser Art von Word Embeddings ist, dass auch Berechnungen durchgeführt werden können. In Abbildung 4 wird dies durch die Vektoren „Mann“, „König“, „Frau“ und „Königin“ deutlich. „Mann“ und „König“ sind ähnlich nah beieinander

wie „Frau“ und „Königin“. Addiert man den Vektor „Frau“ und den Vektor „König“ (gestrichelt dargestellt) ergibt sich der Vektor für „Königin“ (Malla 2024).

Durch die enorme Menge an Daten, die für das Training solcher Modelle verwendet werden, ergibt sich eine unzählbare Anzahl solcher hochdimensionaler Vektoren. Diese werden in durchsuchbaren Vektordatenbanken gespeichert. Es gibt verschiedene Algorithmen, um Embeddings zu verwirklichen. Die bekannteren Algorithmen sind Word2Vec oder Bert (Bidirection Encoder Representation from Transformers). Die bekannten Firmen im KI-Bereich haben bereits trainierte Embeddings verfügbar. Dazu gehören OpenAIs text-embedding-ada-002 oder Google Gemini Modelle, wie text-embedding-004. Welches Modell das Richtige ist hängt vom jeweiligen Anwendungsfall ab. Ein zentraler Faktor sind die Kosten, welche zwischen den Anbietern der trainierten Modelle stark variieren (Kimothi 2024).

Eine besonders fortschrittliche Klasse von auf Deep Learning basierenden NLP-Modellen sind die Large Language Models. Sie zielen darauf ab menschliche Sprache zu „verstehen“, zu verarbeiten und zu generieren. LLMs sind große neuronale Netzwerke, die auf riesigen Datenmengen trainiert werden. Die bekanntesten Beispiele sind die folgenden (Foster/Friston 2023, S. 396):

- GPT (Generative pre-trained transformer): Modelle wie das aktuelle GPT-4o von OpenAI
- LLaMA (Large Language Model Meta AI): Ein Modell von Meta.
- DeepSeek-R1: Ein LLM des Chinesischen Herstellers DeepSeek

LLMs haben sich auf Grund ihrer Flexibilität großflächig durchgesetzt. Das gleiche Modell kann verwendet werden, um Fragen zu beantworten, Texte zusammenzufassen, Inhalt zu erstellen und noch vieles mehr, solange sich der Anwendungsfall auf ein Text-zu-text-Problem runterbrechen lässt. Hierzu muss lediglich die Anweisung (Prompt) als Input in das Modell eingegeben werden. Das LLM ergänzt diesen Prompt Token um Token basierend auf Wahrscheinlichkeiten. Token beschreiben ein Textfragment, dass LLMs für die Eingabe und Ausgabe verwenden. Ein Token kann ein Wort, ein Teil eines Wortes, ein Zeichen oder sogar ein Leerzeichen sein, abhängig davon, wie der Text segmentiert wird. LLMs sagen den Token voraus, der am wahrscheinlichsten auf den Vorhergegangenen folgt. Eine Datenbank mit Fakten oder Textausschnitten, um sie in die Antwort einzufügen, haben LLMs daher nicht. Für einen

angemessenen Umgang mit LLMs ist dies wichtig zu wissen. Sie haben keinen weiteren Abgleich zur Realität, der sie faktische oder logische Fehler erkennen lassen würde (Foster/Friston 2023, S. 396 ff).

Anwendungsbereiche von Natural Language Processing

Einige der vielfältigen Anwendungsmöglichkeiten wurden bereits im vorherigen Kapitel angedeutet. Schon einfache auf maschinellem Lernen basierte NLP-Systeme eignen sich hervorragend für die Klassifizierung von Texten. So können beispielsweise Spam-Mails gefiltert werden oder Kundenrückmeldungen nach „Positiv“, „Negativ“ und „Neutral“ sortiert werden. Auf Deep Learning basierende Ansätze und LLMs werden bereits jetzt in vielen Unternehmen als Chat-Bots, Übersetzer oder zum Zusammenfassen von Dokumenten verwendet (Salesforce Inc. 2025).

Vorteile und Einschränkungen des Natural Language Processing

Die Vorteile von NLP-Systemen liegen neben der häufig erwähnten Vielseitigkeit besonders in der Leistung. Sie vermögen es große Datenmengen zu verarbeiten und somit enorme Textmengen zu analysieren, extrahieren und strukturieren. Auch bei der Textgenerierung ist die Leistung und Geschwindigkeit ein großer Vorteil, um schnell kohärente und gut verständliche Texte zu erstellen und somit auch kreative Aufgaben zu übernehmen. Durch die ständige Weiterentwicklung der entsprechenden Hardware und der Algorithmen, lässt sich sogar eine fast exponentielle Steigerung der Leistung voraussagen (Blessing 2023). Einen weiteren Vorteil bieten die Personalisierungsmöglichkeiten. LLMs lassen sich ganz spezifisch an Zielgruppen anpassen und auf eigenen Serverinstanzen installieren. So sind sie hervorragend skalierbar, sobald sie einmal trainiert sind (IBM 2021a).

Wie schon im Kapitel zu Deep Learning erklärt, ist die Black-Box-Problematik auch bei NLPs eine Herausforderung. Ihre Ausgaben sind schwer nachvollziehbar, was zu ethischen und inhaltlichen Problemen führen kann. Mangels Wissensdatenbank und auf Grund von nur bedingtem Echtzeitwissen, kann es zu logisch oder inhaltlichen Fehlern kommen, die unentdeckt bleiben, da nicht klar ist, woher ein Ergebnis kommt. Es gilt also Aussagen von LLMs immer auf Richtigkeit zu prüfen, bevor diese weiterverarbeitet werden. Des Weiteren können Stereotypen und Vorurteile aus Trainingsdaten mit übernommen werden, was zu diskriminierenden Ausgaben führen kann. Daher ist es wichtig auf ethische und regulatorische Bedenken einzugehen, was wiederum auch

Fragen zu Datenschutz, Sicherheit und Verantwortung aufwirft. Abschließend, können LLMs auch für böartige Zwecke missbraucht werden und durch das Schaffen von z. B. Fake News großen gesellschaftlichen Schaden anrichten. In Zeiten immer leistungsfähigerer generativer KI inkl. LLMs ist es daher unabdingbar, einen bewussten Umgang damit zu etablieren. Hierzu wäre es beispielsweise angebracht, dies frühzeitig im Bildungssystem zu etablieren (Wood 2020).

2.4.5 Robotic Process Automation

In diesem Kapitel wird die Technologie Robotic Process Automation (RPA) beschrieben. RPA ist eine Softwaretechnologie zur Automatisierung von regelbasierten, repetitiven Geschäftsprozessen. Anders als der Name vermuten lässt, handelt es sich dabei nicht um physische Roboter, sondern um Software-Bots, die Aufgaben übernehmen, die zuvor von Menschen manuell ausgeführt wurden. Ein „Roboter“ im RPA-Kontext entspricht einer Software, die konfiguriert wird, um Prozesse effizient abzuwickeln. Durch den Einsatz von solchen Robotern können manuelle und zeitaufwendige Aufgaben effizienter gestaltet werden. Im Kontext des Bid und Proposal-Managements bietet RPA großes Potenzial, besonders in der Automatisierung von Aufgaben im Datenmanagement und der Dokumentenerstellung. Im Gegensatz zu physischen Robotern ist RPA eine rein softwarebasierte Lösung, die direkt auf der Benutzeroberfläche von Anwendungen arbeitet, ähnlich wie ein Mensch Maus und Tastatur verwenden würde (Lacity 2016, S. 3 ff).

Funktionsweise von Robotic Process Automation

Der Kern der RPA-Technologie basiert auf der Automatisierung von Prozessen, die auf vordefinierten Regeln und strukturierten Daten beruhen. Zunächst wird der zu automatisierende Geschäftsprozess identifiziert und in einzelne Schritte zerlegt. Diese Schritte werden dann mithilfe von RPA-Software konfiguriert. Häufig geschieht dies über eine benutzerfreundliche Drag-and-Drop-Oberfläche, die keine tiefgehenden Programmierkenntnisse erfordert. Die RPA-Plattform generiert automatisch den zugrundeliegenden Code, während der Anwender lediglich die Prozesslogik definiert. RPA-Bots interagieren mit Anwendungen über die Benutzeroberfläche (GUI) und verwenden dabei Technologien wie Screen Scraping (das automatische Lesen des auf dem Bildschirm ausgegebenen Textes), optische Zeichenerkennung (OCR – Optical Character Recognition – zur Umwandlung von z. B. handgeschriebenen Texten oder PDFs in

maschinenlesbare Texte) und API-Integrationen. Während einfache RPA-Bots Aufgaben, wie das Kopieren von Daten von einer Excel-Tabelle in ein ERP-System erledigen, können fortgeschrittene Bots mithilfe von OCR unstrukturierte Daten aus PDFs extrahieren und verarbeiten. Darüber hinaus ermöglicht die Integration von APIs den direkten Datenaustausch zwischen Systemen, was die Geschwindigkeit und Effizienz der Prozesse weiter verbessert. Ein weiteres zentrales Merkmal von RPA ist der nicht-invasive Ansatz. Die Software arbeitet auf der Präsentationsebene der IT-Systeme, ohne Änderungen an der zugrunde liegenden Infrastruktur oder den Datenbanken vorzunehmen. Dies erleichtert die Implementierung von RPA erheblich, da bestehende Systeme nicht angepasst werden müssen. Die Bots greifen mit eigenen Anmeldeinformationen auf Anwendungen zu und führen Aufgaben wie ein menschlicher Nutzer aus, was den Integrationsaufwand reduziert und die Kompatibilität mit verschiedenen IT-Umgebungen sicherstellt. Darüber hinaus ist RPA skalierbar und kann einfach an unterschiedliche Geschäftsanforderungen angepasst werden. Bots lassen sich zentral überwachen, steuern und verwalten, was eine hohe Transparenz und Nachverfolgbarkeit der durchgeführten Prozesse gewährleistet. Besonders in regulierten Branchen ist dies ein Vorteil, da RPA automatisch Audit-Trails erstellt und somit die Einhaltung von Compliance-Vorgaben unterstützt (Lacity 2016; Wright/Witherick/Gordeeva 2017; Figueroa-García 2017).

Anwendungsbereiche von Robotic Process Automation

Als Aufgaben, die durch RPA automatisiert werden können, eignen sich besonders solche, die geringe kognitive Anforderungen haben, also kein subjektives Urteilsvermögen, keine Kreativität und keine Interpretationsfähigkeiten erfordern. Außerdem sollten sie häufig und in großen Mengen ausgeführt werden und dabei auf Grund der manuellen Tätigkeiten anfällig für menschliche Fehler sind. Die Automatisierung wird einfacher, wenn die Aufgaben wenige oder keine Ausnahmen haben (Figueroa-García 2017, S. 3).

Klassische Anwendungsbereiche von RPA in Unternehmen, die die oben genannten Bedingungen erfüllen, sind z. B. Finanz- und Rechnungswesen, Personalwesen und IT-Management. Im Rechnungswesen eignet sich RPA für die automatisierte Erfassung, Prüfung und Buchung von Rechnungen in ERP-Systemen, für die Automatisierung von Zahlungsabgleichen oder für das Mahnwesen. Mitarbeiter-Onboarding Prozesse wie das automatisierte Erstellen von Arbeitsverträgen oder das Anlegen von

Mitarbeiterprofilen werden bereits ebenso durch RPA automatisiert, wie die Übertragung von Daten zwischen Systemen bei Infrastrukturumstellungen im IT-Management (Singureanu 2025).

Auch im Proposal Management ist eine Automatisierung einiger Prozesse denkbar. Beispielsweise könnten RPA-Bots relevante Informationen aus Ausschreibungsunterlagen oder CRM-Systemen in Angebotsvorlagen einfüllen. Die können auch vordefinierte Textbausteine und Vorlagen ausfüllen, um somit automatisiert Angebotsunterlagen zusammenzustellen. Des Weiteren könnten komplexe Genehmigungs- und Freigabeprozesse durch das automatisierte Weiterleiten von erforderlichen Dokumenten an die zuständigen Personen und anschließender Überwachung des Status automatisiert werden.

Vorteile und Einschränkungen von Robotic Process Automation

Die Implementierung von RPA in Unternehmen bietet einige Vorteile. Insbesondere lässt sich durch die Automatisierung die Effizienz von Prozessen enorm steigern. Bots können Aufgaben ohne Pausen, rund um die Uhr ausführen und Prozesse, die manuell Stunden dauern würden, in Minuten abschließen. Weil die Implementierung von RPAs ohne tiefgreifende Änderungen an der bestehenden IT-Infrastruktur einhergeht, und auch die zugrundeliegenden Prozesse nicht nachhaltig verändert, lassen sie sich im Vergleich zu traditionellen IT-Projekten relativ schnell umsetzen. Sollten RPA-Lösungen erweitert werden, ist das ohne große Investitionen in die Infrastruktur möglich, es müssen lediglich mehr Bots bereitgestellt werden (Wright/Witherick/Gordeeva 2017).

Neben den Vorteilen, hat RPA auch einige Einschränkungen, denen man sich bewusst sein muss. Diese ergeben sich zum einen aus der Begrenzung auf regelbasierte Prozesse. Komplexe Aufgaben, die kognitive Fähigkeiten erfordern, können durch Bots nicht effizient bearbeitet werden. Daraus ergibt sich ein hoher Wartungsaufwand bei Systemänderungen. Sollten sich im Unternehmen Benutzeroberflächen, Datenstrukturen oder IT-Systeme ändern, müssen die Bots häufig neu konfiguriert werden, was zu Kosten und unerwarteten Ausfallzeiten führen kann. Außerdem kann es durch die Automatisierung von ineffizienten Prozessen zu einem Verstecken eben dieser kommen, sodass man die Schwächen dieser Prozesse nur „maskiert“, statt sie zu optimieren. Zu guter Letzt kann es durch die Implementierung von RPA potenziell zu Arbeitsplat-

zunsicherheit kommen, da Bots teilweise die Arbeit der Mitarbeiter übernehmen. Dieser Angst muss entsprechend begegnet werden, um den kulturellen Wandel im Unternehmen nicht unnötig zu erschweren (Safar 2019).

Abschließend zu Kapitel 2 lässt sich festhalten, dass es verschiedene Arten von Künstlicher Intelligenz gibt, die unterschiedliche Vor- und Nachteile haben und sich dadurch für spezielle Anwendungsfälle eignen. Im Folgenden wird das Bid Management vorgestellt, welches als potenzielles Anwendungsfeld von KI zunächst beschrieben und dann untersucht wird.

3 Grundlagen des Bid Managements

Für die Beantwortung der Forschungsfrage ist neben dem Verständnis für Künstliche Intelligenz und deren verschiedensten Arten, ein Einblick in das Anwendungsfeld Bid Management notwendig. Daher wird im Folgenden Bid Management nach dem APMP-Standard der Association of Proposal Management Professionals (APMP) erklärt und die Aufgaben des Bid Managers aufgezeigt. Anschließend wird der Ende-zu-Ende *Business Development* Prozess dargestellt, der den Rahmen für das Bid Management bietet und erklärt, warum Digitalisierung in diesem Bereich unerlässlich ist.

Ein Bid Manager ist eine leitende Vertriebsrolle innerhalb einer Organisation, verantwortlich für das Management von Angeboten, in der Regel als Antwort auf RFQs (Request for Quotation, Angebotsaufforderung), aber auch als proaktive Akquisitionen von Geschäften. Bid Manager leiten die Erarbeitung der Lösung und die Erstellung des Angebots als „Bid Project Manager“, um die Einhaltung der Kundenanforderungen sicherzustellen und gleichzeitig die Werte (Value Propositions) des Unternehmens herauszustellen. Im Bid Management arbeitet man oft eng mit Hauptabteilungsleitern und der Geschäftsleitung (z. B. CEO, CFO) zusammen, um strategische Ansätze zum Gewinnen von Angeboten zu erarbeiten und umzusetzen (Newman 2011).

Bid Management ist Teil des Business Development Prozesses (BD) eines Unternehmens, welcher aus mehreren Phasen besteht. Am Anfang des BD steht die *Market Identification* (Marktidentifikation), in der ein Markt in unterschiedliche Segmente eingeteilt wird, um Angebote gezielt auf die spezifischen Bedürfnisse des Segmentes auszurichten. Im Anschluss kommt die Phase *Account Planning* (Accountplanung). Für jeden großen Kunden werden separate Pläne erarbeitet, wie man mehrere *Opportunities* (Verkaufsmöglichkeiten) dieses Kunden adressiert. Die nächste Phase ist das *Opportunity Assessment* (Bewertung der Verkaufsmöglichkeit), innerhalb derer wird eine spezifische Opportunity daraufhin überprüft, ob sie zu den Interessen, Fähigkeiten und verfügbaren Ressourcen passt, um ein Angebot zu erstellen und das Projekt zu implementieren. In der folgenden *Proposal Planning* Phase (Angebotsplanung) wird der Aufwand der Angebotserstellung geplant. Das Angebot wird dann in der Phase *Proposal Development* (Angebotsausarbeitung) erstellt, geprüft, freigegeben und schließlich dem Kunden übermittelt. In der *Negotiation Phase* (Verhandlungsphase) wird die Verhandlung mit dem Kunden vorbereitet und durchgeführt. Nach der Verhandlung wird ein *Best and Final Offer* (BAFO, Bestes und letztes Angebot) erstellt und abgegeben.

Ist der Vertrag unterschrieben, wird die verhandelte Lösung bzw. das verhandelte Projekt in der *Delivery Phase* (Lieferungsphase) geliefert. In der Phase gilt es weiterhin eine gute Beziehung mit dem Kunden aufrecht zu erhalten und möglichst weitere *Opportunities* zu erheben. Jede dieser Phasen endet in einem Meilenstein, so genannten *Bid Decisions* (Angebots Entscheidung) in denen überprüft wird, ob eine *Opportunity* weiterhin verfolgt und ein Angebot erstellt und abgegeben werden soll. Dies dient dazu die *Win-Rate* (Erfolgsquote) zu erhöhen, und Ressourcen zu schonen (APMP 2022a).




Abbildung 5: Business Development Prozess (eigene Darstellung)

Die Angebotserstellung gleicht in vielerlei Hinsicht einem Projekt, was dazu führt, dass sich Projektmanagementgrundsätze ebenso auf das Bid Management während der Angebotsphase anwenden lassen. Um aus den Kundenanforderungen der Ausschreibung ein kundenorientiertes, wettbewerbsfähiges und für das Unternehmen möglichst wenig risikobehaftetes Angebot zu erstellen, braucht man ein Bid Team, das die gleichen Anforderungen an die Leitung stellt wie ein Projektteam. Verstärkend kommt die Zeit als restriktiver Faktor dazu. Ein RFQ beinhaltet immer eine definiertes Abgabedatum, das erfahrungsgemäß acht bis zehn Wochen nach Veröffentlichung liegt. Durch Bieterfragen kann eine Abgabefrist verlängert werden. Der Kunde hat allerdings die Möglichkeit, eine solche Anfrage abzulehnen. Eine der Hauptaufgaben des Bid Managers ist es daher, dem Team die Struktur und die Tools zu bieten, die es ermöglichen, das Angebot *in Time*, *in Cost* und *in Quality* zu erstellen (APMP 2022c).

Zum Bid Management lässt sich abschließend zusammenfassen, dass es ein sehr spezialisierter Unternehmensbereich ist, dessen größte Restriktion der Faktor Zeit ist. Dieses Kapitel bildet den Abschluss der Erarbeitung der theoretischen Grundlagen, deren Ergebnisse in einem Zwischenfazit zusammengefasst und eingeordnet werden.

4 Zwischenfazit

Die Analyse der theoretischen Grundlagen zu Künstlicher Intelligenz und Bid Management zeigt, dass sich beide Themenfelder durch eine hohe Komplexität und eine teilweise unübersichtliche Literaturlage auszeichnen. Besonders im Bereich der Künstlichen Intelligenz fällt auf, dass es keine einheitliche Definition von KI und ihren Unterarten gibt. Vielmehr existieren zahlreiche Begriffsverständnisse, die je nach wissenschaftlicher Disziplin, technischer Ausrichtung oder praktischer Anwendung variieren. Die Begriffe schwache und starke KI sowie symbolische und subsymbolische KI helfen dabei, eine erste Orientierung zu schaffen, zeigen jedoch zugleich die Vielschichtigkeit des Forschungsfeldes auf.

Die Literatur verdeutlicht diese Problematik. Veröffentlichungen zur Künstlichen Intelligenz sind häufig entweder sehr technisch und setzen umfangreiche IT- und Mathematikkenntnisse voraus, oder bewegen sich im Bereich der populärwissenschaftlichen Darstellung. Insbesondere wissenschaftlich fundierte, aber für Management- oder Businesskontexte zugängliche Darstellungen sind bislang kaum vorhanden bzw. schwer zu identifizieren. Diese Lücke erschwert es, KI systematisch und praxisnah für Nicht-IT-Experten greifbar zu machen.

Noch ausgeprägter zeigt sich diese Problematik im spezifischen Themenfeld der Künstlichen Intelligenz im Bid Management. Das Bid Management selbst ist ein hochspezialisiertes Aufgabengebiet, das in der Fachliteratur ohnehin nur begrenzt behandelt wird. In Kombination mit KI finden sich fast ausschließlich marketingorientierte Beiträge, etwa in Form von Whitepapers oder Blogartikeln von Softwareanbietern. Wissenschaftlich fundierte Untersuchungen zur Implementierung von KI im Bid Management fehlen weitgehend. Dies erschwert eine umfassende theoretische Betrachtung und zwingt dazu, neue Erkenntnisse auf Basis praktischer Erfahrungen und Expertenwissen zu gewinnen.

Aus diesen Gründen wurde im Rahmen dieser Arbeit entschieden, die Herausforderungen des Bid Managements und mögliche Einsatzfelder von KI über eine empirische Herangehensweise zu erschließen. Die gewählte Methodik der Experteninterviews ermöglicht es, durch gezielte Befragung erfahrener Bid Manager tiefere Einblicke in die tatsächlichen Problemstellungen und Anforderungen des Arbeitsalltags zu erhalten. Auf dieser Grundlage sollen praxisnahe Ideen für potenzielle Anwendungsbereiche

von Künstlicher Intelligenz im Bid Management entwickelt werden. Die Experteninterviews ergänzen somit die theoretische Erarbeitung um eine praxisorientierte Perspektive und bilden das Fundament für die weitere Ableitung von Handlungsempfehlungen.

5 Experteninterviews

Um die Lücke des Theorieteils der Arbeit, insbesondere in Bezug auf die Herausforderungen im Bid Management und den möglichen Anwendungsfeldern von KI in diesem Bereich zu schließen, wurde sich entschieden Experteninterviews durchzuführen. Dieses Kapitel beschreibt zunächst die gewählte Methode der Experteninterviews generell und stellt anschließend den Interviewleitfaden und die Experten vor. Abschließend werden die Erkenntnisse der Interviews zusammengefasst.

5.1 Methodik der Experteninterview

Das Experteninterview ist eine qualitative Forschungsmethode, die sich insbesondere zur Gewinnung von tiefgehenden Informationen über spezifische Themenbereiche eignet. Es wird eingesetzt, um Expertenwissen zu systematisieren und für wissenschaftliche Analysen nutzbar zu machen (Bogner/Littig/Menz 2014, S. 2 ff).

Experten sind Personen, die über ein spezifisches Wissen oder eine besondere Erfahrung in einem bestimmten Fachgebiet verfügen. Dieses Wissen kann sowohl formal als auch informell erworben sein. In der qualitativen Forschung werden Experten oft als „Wissenseliten“ betrachtet, da sie aufgrund ihrer spezialisierten Kenntnisse wertvolle Einblicke in komplexe Sachverhalte liefern können (Bogner/Littig/Menz 2014, S. 13 f).

Im Rahmen dieser Arbeit wurden theoriegenerierende Experteninterviews durchgeführt. Ziel dieser Methodik ist es, subjektive Deutungsmuster der Experten zu rekonstruieren und daraus Hypothesen und Theorien über die Nutzung von KI im Bid Management zu entwickeln. Diese Form des Interviews geht über die reine Informationsgewinnung hinaus und erlaubt, latentes Wissen, Deutungen und Handlungsrouninen systematisch zu erfassen (Bogner/Littig/Menz 2014, S. 25).

Auswahl der Experten

Die Auswahl der Interviewpartner erfolgt zielgerichtet nach dem Prinzip des theoretischen Samplings (Bogner/Littig/Menz 2014, S. 36). Kriterien für die Auswahl sind unter anderem die Fachkompetenz, die Relevanz der Erfahrung sowie die Zugänglichkeit der Person. Im Rahmen dieser Masterarbeit wurden zwei Bid Manager der Airbus Secure Land Communications GmbH ausgewählt, die jeweils eine langjährige Berufserfahrung im Bid Management vorweisen können. Ein Interviewpartner verfügt über 7

Jahre Berufserfahrung als Bid Manager, der andere hat bereits 15 bis 20 Jahre in verschiedenen Rollen (Bid Manager, Pricing Manager, Projektmanager) bei globalen Telekommunikationsunternehmen.

Durch diesen unterschiedlichen Erfahrungsschwerpunkt und das abweichende Alter der Teilnehmer wird eine breite Perspektive auf die Herausforderungen im Bid Management sowie auf den möglichen Einsatz von Künstlicher Intelligenz gewährleistet. Beide sind mit den Abläufen und Anforderungen komplexer Ausschreibungen vertraut und gelten aufgrund ihrer langjährigen Tätigkeit in nationalen wie internationalen Projekten als ausgewiesene Experten auf ihrem Gebiet.

Gestaltung des Leitfadens

Ein semistrukturierter Leitfaden dient als Grundlage für das Experteninterview. Er enthält offene Fragen, die eine flexible Gesprächsführung ermöglichen, gleichzeitig aber eine Vergleichbarkeit der Interviews sicherstellen (Bogner/Littig/Menz 2014, S. 31 ff). Für diese Masterarbeit wurde folgender Interviewleitfaden ausgearbeitet.

Interviewleitfaden

1) Beruflicher Hintergrund und Erfahrung im Bid Management:

- a) Können Sie sich bitte kurz vorstellen und Ihre berufliche Laufbahn im Bid Management skizzieren?

2) Herausforderungen im Bid Management:

- a) Welche Herausforderungen sehen Sie besonders kritisch für das Bid Management an?

3) Wahrnehmung und Erfahrung mit Künstlicher Intelligenz (KI):

- a) Wie definieren Sie Künstliche Intelligenz?
- b) Welche konkreten Erfahrungen haben Sie bisher mit KI gemacht?

4) Potenziale von KI zur Bewältigung der Herausforderungen:

- a) Welche Möglichkeiten sehen Sie, KI gezielt einzusetzen, um bestehende Herausforderungen im Bid Management zu bewältigen?
- b) Gibt es konkrete Anwendungsfälle oder bereits implementierte Lösungen, die Sie als erfolgversprechend einschätzen?

5) Weitere Anwendungsfälle für KI im Bid Management:

- a) Sehen Sie über die bereits besprochenen Ansätze hinaus weitere Potenziale für den Einsatz von KI im Bid Management?

- b) Welche zukünftigen Entwicklungen erwarten Sie in diesem Bereich, und wie könnte sich das Rollenbild von Bid Managern dadurch verändern?

Durchführung des Interviews

Die Interviews werden in einer persönlichen Gesprächssituation bzw. über Videokonferenz geführt und aufgezeichnet. Dies ermöglichte detaillierte Auswertung. Während der Gespräche wird eine offene und respektvolle Gesprächsatmosphäre angestrebt, um eine möglichst authentische und vollständige Darstellung des Expertenwissens zu gewährleisten.

Auswertung der Experteninterviews

Die Auswertung erfolgt anhand einer qualitativen Inhaltsanalyse (Bogner/Littig/Menz 2014, S. 72 f). Hierbei werden die Interviews systematisch codiert und zentrale Themen, Muster und Deutungen herausgearbeitet. Das Ziel besteht darin, theoriegeleitet Hypothesen über die Herausforderungen und die Potenziale des KI-Einsatzes im Bid Management zu entwickeln. Dabei wird darauf geachtet, sowohl explizite als auch implizite Inhalte zu berücksichtigen.

Gütekriterien und Herausforderungen

Zur Sicherung der Qualität wird auf Transparenz und Nachvollziehbarkeit geachtet. Der Ablauf der Experteninterviews sowie die Auswertung werden systematisch dokumentiert. Eine Herausforderung besteht darin, die Interviews offen genug zu gestalten, um neue Aspekte zuzulassen, ohne den thematischen Rahmen zu verlieren. Durch die Anwendung etablierter methodischer Standards sollte die Belastbarkeit der Ergebnisse gewährleistet werden (Bogner/Littig/Menz 2014, S. 92 ff).

5.2 Vorstellung der Experten

Im Rahmen dieser Arbeit wurden zwei Experteninterviews durchgeführt. Nachfolgend werden die Interviewpartner vorgestellt.

Experte 1 verfügt über eine rund siebenjährige Berufserfahrung im Bereich des Bid Managements, davon etwa drei Jahre in der Abteilung Bid Management der Airbus Secure Land Communications GmbH. Nach seinem Managementstudium begann er seine Karriere in einer Hamburger Beratungsfirma, die auf industrielle Forschungs-

und Entwicklungsprojekte spezialisiert war. Dort war er als Bid Manager tätig und betreute Kunden aus verschiedenen Branchen, darunter Luft- und Raumfahrt, Automotive und Energie. Anschließend wechselte er zur Airbus Secure Land Communications GmbH, einem Unternehmen im Bereich Kommunikationssysteme, wo er weiterhin als Bid Manager tätig ist.

Experte 2 kann auf eine Berufserfahrung von rund 15 bis 20 Jahren im Bid Management zurückblicken. Seine Laufbahn umfasst verschiedene Funktionen im Angebots- und Projektmanagement, unter anderem bei großen Unternehmen der Telekommunikationsbranche. Dabei betreute er Kunden über den gesamten Angebots- und Projektzyklus hinweg. Von der ersten Anbahnung über die Ausschreibung bis zur finalen Umsetzung und Abnahme. Neben seiner praktischen Tätigkeit im Bid Management war Experte 2 auch als Trainer für den Bereich aktiv und absolvierte mehrere einschlägige Zertifizierungen.

5.3 Ergebnisse aus den Interviews

Folgenden werden die zentralen Ergebnisse entlang der thematischen Schwerpunkte des Interviewleitfadens dargestellt.

Herausforderungen im Bid Management

Beide Experten betonen, dass der Bid-Management-Prozess stark von Zeitdruck und begrenzten Ressourcen geprägt ist. Angebote müssen häufig unter hohem Zeitdruck erstellt werden, was zu Engpässen in der Qualitätssicherung führen kann.

Experte 1 hebt besonders die Problematik hervor, dass Anforderungen in Ausschreibungen oft unpräzise oder widersprüchlich formuliert sind, was zu erheblichem Abstimmungsaufwand führt. Zudem kritisiert er die mangelnde Standardisierung in Angebotsdokumenten, was wiederkehrende Aufgaben erschwert und die Effizienz senkt.

Experte 2 sieht die größte Herausforderung in der Koordination zwischen verschiedenen Fachabteilungen. Er beschreibt, dass es häufig schwierig sei, rechtzeitig die notwendigen Informationen und Ressourcen aus anderen Unternehmensbereichen bereitzustellen. Außerdem betont er den hohen Wettbewerbsdruck in öffentlichen Ausschreibungen, bei dem geringe Preisunterschiede entscheidend sein können.

Wahrnehmung und Erfahrung mit Künstlicher Intelligenz

Auf die Frage, wie sie Künstliche Intelligenz definieren würden, nennen beide Experten ähnliche Kernmerkmale: Experte 1 versteht KI als die Fähigkeit von Systemen, Daten eigenständig zu verarbeiten und Entscheidungen auf Basis von Algorithmen zu treffen. Experte 2 beschreibt KI als Technologie, die menschliches Entscheidungsverhalten nachahmt und eigenständig aus Erfahrungen lernen können.

In Bezug auf eigene Erfahrungen berichten beide Experten eher von ersten Berührungspunkten als von tiefgreifender praktischer Anwendung. Experte 1 erwähnt den Einsatz einfacher Automatisierungstools und eine theoretische Beschäftigung mit KI-Technologien, insbesondere im Bereich Textverarbeitung und Informationsrecherche. Experte 2 verweist auf erste private Experimente mit Chatbots und LLMs.

Generell zeigt sich, dass beide Experten ihr Wissen über KI eher aus den Nachrichten und populärwissenschaftlichen Dialogen haben und weniger auf eigene Erfahrung oder Recherche zurückgreifen können.

Potenziale von KI zur Bewältigung der Herausforderungen

Beide Experten sehen grundsätzlich großes Potenzial für den Einsatz von KI im Bid Management, insbesondere zur Entlastung von Routineaufgaben und zur Verbesserung der Informationsaufbereitung. Experte 1 sieht in der automatischen Analyse von Ausschreibungsdokumenten ein wichtiges Einsatzfeld. Er betont, dass KI helfen könnte, relevante Anforderungen schneller zu extrahieren und so die Anforderungsanalyse effizienter zu gestalten. Experte 2 verweist auf die Möglichkeit, durch Künstliche Intelligenz Fristen, Anforderungen und wichtige Informationen automatisch zu extrahieren und zu priorisieren. Er hält dies für besonders relevant, da so der Zeitdruck bei der Erstellung komplexer Angebote reduziert werden könnte. Darüber hinaus identifizieren beide Experten Potenziale im Bereich der Textgenerierung. KI-Systeme könnten Standardtexte oder erste Entwürfe für Angebotsabschnitte erstellen, die dann vom Bid Team angepasst würden.

Beide Experten betonen, dass die strategische Arbeit, wie etwa die Positionierung gegenüber dem Kunden, weiterhin vom Bid Manager selbst übernommen werden müsse. KI könne jedoch helfen, mehr Zeit für diese Aufgaben zu schaffen, indem sie Standardprozesse beschleunigt.

Konkrete Anwendungsfälle und bestehende Lösungen

Als konkreten Anwendungsfall, wendete Experte 1 in seinem vorherigen Unternehmen bereits ein einfaches, regelbasiertes Tool an, das Keywords in Dokumenten extrahiert, sieht aber den Bedarf für weiterentwickelte KI-Systeme, die Inhalte wirklich verstehen. Experte 2 berichtet von automatisierten Prüfprozessen, bei denen kleine Standardangebote auf Basis weniger Eingaben validiert wurden. Auch wenn bestehende Lösungen noch nicht alle Anforderungen erfüllen, sehen beide Interviewpartner erste vielversprechende Ansätze.

Zusätzlich könnten RPA-Systeme Routineaufgaben wie das Kopieren von Daten aus ERM- und CRM-Systemen in Angebotsdokumente übernehmen.

Weitere Anwendungsfälle für KI im Bid Management und Entwicklung der Rolle

Über die genannten Ansätze hinaus sehen beide Experten weitere Einsatzmöglichkeiten. Experte 1 erwartet, dass KI künftig LLMs bei der Angebotserstellung unterstützen könnte und sich der Fokus des Bid Managers stärker auf Review und Strategiearbeit verlagern werde. Er geht davon aus, dass dadurch repetitive Aufgaben wie die Texterstellung weitgehend automatisiert werden könnten. Experte 2 prognostiziert den Einsatz von Predictive Analytics, etwa zur Vorhersage von Gewinnwahrscheinlichkeiten bei Angeboten. Auch eine Unterstützung bei Pricing-Prozessen hält er für denkbar, etwa durch KI-gestützte Vorschläge auf Basis historischer Daten.

Beide Experten stimmen darin überein, dass der Bid Manager künftig stärker die Rolle eines strategischen Koordinators einnehmen wird, der KI-Systeme steuert und deren Ergebnisse kritisch bewertet. Vollständige Automatisierung sei nicht zu erwarten; menschliche Erfahrung und Qualitätskontrolle würden weiterhin unverzichtbar bleiben.

Trotz mangelnder Erfahrung mit KI, könnten die beiden Experten Ideen für die Nutzung von KI im Bid Management liefern, die im späteren Verlauf dieser Arbeit mit den bereits erarbeiteten KI-Technologien zusammengebracht werden. Die Interviews ermöglichen eine gute Einschätzung der Herausforderungen des Bid Managements, die im folgenden Kapitel detailliert werden, um sich der Beantwortung der Forschungsfrage weiter zu nähern.

5.4 Herausforderungen im Bid Management

Im Rahmen von Ausschreibungsprozessen treten für Unternehmen und Bid Manager, insbesondere in technisch anspruchsvollen Branchen, diverse Herausforderungen auf. Diese lassen sich unter anderem auf zeitliche Restriktionen, unklare Anforderungen sowie Ressourcen- und Abstimmungsprobleme zurückführen. Dabei ist laut Experte 1 eine gute Vorbereitung essenziell. Häufig wird das Bid Management jedoch erst spät priorisiert, was zu Engpässen führen kann, wenn Ausschreibungen kurzfristig bearbeitet werden müssen. Hierbei betont Experte 1, dass eine frühzeitige Identifikation neuer Ausschreibungen enorm hilfreich sein kann, um rechtzeitig das erforderliche Team zusammenzustellen und eine wettbewerbsfähige Strategie zu entwickeln.

Zeitdruck gilt als eine zentrale Herausforderung, da viele Ausschreibungen ein enges Zeitfenster vorgeben. Kommt es zu technischen oder organisatorischen Problemen, kann die Pufferzeit schnell aufgebraucht sein, sodass komplexe Lösungsschritte unter erheblichem Stress erfolgen müssen. In diesem Zusammenhang ist auch der Aspekt der Anforderungsanalyse (Requirements Management) besonders herausfordernd. Wie Experte 2 berichtet, sind Kundenanforderungen oft unklar oder nicht eindeutig aus den RFQ-Dokumenten ersichtlich. Diese Uneindeutigkeit erfordert eine intensive Abstimmung sowohl mit dem Kunden als auch unternehmensintern, um zu klären, was tatsächlich gefordert wird und wie man den Bedarf realistisch abbilden kann.

Neben der zeitlichen Komponente und den unklaren Anforderungen hebt Experte 2 zudem die Schwierigkeiten hervor, intern die richtigen Ressourcen zu mobilisieren. In vielen Unternehmen sind Expertinnen und Experten in parallelen Projekten gebunden, sodass das Bid-Team sich stark um Unterstützung bemühen muss. Ähnlich sieht es Experte 1, wenn es um das Zusammenstellen fachlicher Inputs geht, insbesondere dann, wenn verschiedene Abteilungen (Technik, Legal, Pricing, etc.) zeitgleich belastet sind. Umso wichtiger seien laut beiden Interviewpartnern eine effiziente Koordination und Priorisierung: Welche Themen sind kritisch und müssen zuerst bearbeitet werden, und welche lassen sich ggf. später oder mit weniger Tiefe abhandeln.

Des Weiteren sehen beide Interviewpartner einen erheblichen Aufwand bei der Qualitätssicherung. So können etwa Widersprüche in Kundendokumenten auftreten, wenn mehrere Autorinnen und Autoren beim Kunden an den Ausschreibungsunterlagen gearbeitet haben. Dies führt zu einem erhöhten Abstimmungsbedarf und zusätzlichen Kontrollschleifen, um Inkonsistenzen zu beheben.

Schließlich spielt auch starker Wettbewerb eine Rolle: Sowohl Experte 1 als Experte 2 haben die Erfahrung gemacht, dass insbesondere internationale Wettbewerber die Preise senken können und so zusätzlichen Druck erzeugen. Dies bedinge, dass das Team nicht nur ein zeitlich und inhaltlich stimmiges Angebot abgeben, sondern auch klare Alleinstellungsmerkmale (Unique Selling Proposition) herausarbeiten muss, um im Vergleich zum Wettbewerb zu bestehen.

Zusammenfassend lassen sich die wichtigsten Herausforderungen im Bid Management anhand der Interviews wie folgt strukturieren:

- Zeitfaktor: Enge Deadlines und verspätete Priorisierung führen zu hohem Druck.
- Unklare oder uneinheitliche Kundenanforderungen erfordern intensive Anforderungsanalysen und Abstimmungen, um eine passgenaue Lösung zu erarbeiten.
- Ressourcenknappheit und Abstimmung: Es ist schwierig, intern frühzeitig alle notwendigen Fachbereiche zu koordinieren.
- Hoher Aufwand bei der Qualitätssicherung: Widersprüchliche Dokumente oder umfangreiche Unterlagen erhöhen den Prüfaufwand.

Diese Herausforderungen spiegeln sich in den Ausführungen beider Experten wider und dienen in der weiteren Ausarbeitung als Grundlage um die Einsatzmöglichkeiten von KI im Bid Management zu betrachten.

6 Einsatzmöglichkeiten und Nutzen von KI im Bid Management

Um zu analysieren welche Einsatzmöglichkeiten KI im Bid Management bietet, werden in diesem Kapitel die in Kapitel 5.4 erarbeitete Herausforderungen des Bid Managements betrachtet und passende Herangehensweisen aus dem Bereich KI zugeordnet. Die Struktur richtet sich nach der Reihenfolge, die anhand der Interviews ausgearbeitet wurde. Für die Betrachtung des Nutzens wird sich auf die Herausforderungen konzentriert, weil an diesen Stellen der größte Hebel für Effizienzgewinnung erwartet wird.

6.1 Reduzierung des Zeitaufwandes durch Robotic Process Automation

Wie in Kapitel 5.4 erarbeitet, ist eine zentrale Herausforderung im Bid Management der enorme Zeitdruck, der aufgrund der häufig eng gesetzten Deadlines des Kunden entsteht. Robotic Process Automation kann genau hier ansetzen, um den Aufwand, der durch eine Vielzahl von repetitiven Tätigkeiten entsteht, zu verringern und somit Zeit für die wichtigen Tätigkeiten zu schaffen. Typische Beispiele solcher Tätigkeiten sind das Kopieren von Kunden- oder Unternehmensdaten in Dokumentenvorlagen oder das Kopieren von Dateien in eine bestimmte Verzeichnisstruktur. Im Bid Management lassen sich RPAs auf verschiedene Arten vorteilhaft einsetzen.

Automatisiertes Erstellen von Angebotsvorlagen

RPA erledigt repetitive Arbeiten, wie „Copy & Paste“ verlässlich und in hoher Geschwindigkeit, was gerade in stressigen Angebotsphasen eine erhebliche Entlastung darstellt. Außerdem führt Stress häufig zu menschlichen Flüchtigkeitsfehlern. Beispielsweise das falsche Eintragen von Kundennamen oder das Übersehen wichtiger Felder in Angebotsdokumenten lassen sich durch Bots minimieren. RPA kann Kundendaten und Preislisten aus CRM-Systemen oder Datenbanken auslesen und in Word- oder PDF-Vorlagen einfügen. Dies verschafft dem Bid-Team mehr Zeit für strategische Aspekte, wie das Herausarbeiten von Alleinstellungsmerkmalen. Eine Aufgabe, die von Experte 1 als besonders wichtig herausgestellt wurde und auch zukünftig für Bid Manager eine immer größere Rolle einnehmen wird.

Dokumentenmanagement

Das systematische Ablegen, Umbenennen und Versionieren von Dokumenten kann ebenfalls automatisiert werden. RPA-Bots können z. B. Ordnerstrukturen nach Vorgaben anlegen und Dateien an verschiedene definierte Pfade verschieben. Außerdem können Dokumente versioniert werden. Besonders bei großen Teams ist es wichtig, dass jeder zu jeder Zeit die richtigen Dokumente in der aktuellen Version zur Verfügung hat. Dies wird so sichergestellt.

Genehmigungs-Workflow

Experte 2 stellt in seinem Interview klar, dass der Genehmigungsprozess im Bid Management sehr wichtig, allerdings auch zeitaufwendig ist. Mit RPA ist es möglich, Freigabe oder Genehmigungsprozesse anzustoßen, in dem etwa Statusmeldungen aus einem Tracking-Tool in das Mailprogramm überführt werden. Auch die Meldung an Vorgesetzte oder Entscheidungsträger bei Verzögerungen kann automatisiert erfolgen.

6.2 Vereinfachung der Anforderungsanalyse durch Natural Language Processing

Eine wesentliche Schwierigkeit im Bid Management besteht darin, unklare oder uneinheitliche Kundenanforderungen in Ausschreibungsdokumenten schnell und präzise zu identifizieren. Natural Language Processing kann dabei unterstützen, große Mengen an Text automatisiert zu analysieren und relevante Inhalte herauszufiltern. Im Rahmen der Anforderungsanalyse lässt sich NLP dadurch auf verschiedene Art und Weisen einsetzen.

Entity Recognition zur semantischen Analyse von RFQ-Dokumenten

Begriffe wie „Liefertermin“, „Muss“, „Soll“, „Kann“ oder besondere technische Spezifikationen werden automatisch identifiziert und hervorgehoben. „Muss“, „Soll“ und „Kann“ sind, besonders in Ausschreibungen öffentlicher Kunden, vordefinierte Wörter, die Anforderungen klassifizierten. Muss-Anforderungen sind Anforderungen, die der Bieter verpflichtend einzuhalten hat, wobei der Bieter bei einer Nichterfüllung der Anforderung vom Verfahren auszuschließen ist. Soll-Anforderungen sind nicht verpflichtend, bei Nichterfüllung werden allerdings Bewertungspunkte abgezogen. Kann-Anforderungen dienen dem Bieter lediglich zur Information. Auf diese Weise wird schnell

ersichtlich welche Textpassagen reine „Hintergrundinformationen“ sind und welche tatsächlich als Pflichtenforderungen gelten. Wie von Experte 1 betont wird, ist nicht immer klar, wo der Kunde nur einen Rahmen skizziert und wo verbindliche Spezifikationen stehen.

Keyword- und Satz-Extraction zur Generation von Anforderungslisten

Neben dem Hervorheben solcher Schlüsselwörter lassen sich solche Formulierungen auch gezielt sammeln und strukturieren, um ein klares Bild der Anforderungen, sortiert nach „Muss“ und „Soll“ zu erhalten. Somit können Anforderungslisten erstellt werden, in denen das Team anschließend Zuständigkeiten und Erfüllungsgrade eintragen kann.

Automatische Textzusammenfassung

Gerade bei umfangreichen Lastenheften oder RFQ-Dokumenten erleichtert eine generierte Kurzfassung den schnellen Überblick. Durch den Einsatz von Large Language Models können diese Zusammenfassungen noch durch Textinterpretationen ergänzt werden, die das Team vor allem bei widersprüchlichen Dokumenten, die Experte 2 beschreibt, entlasten.

6.3 Entlastung der Ressourcen durch maschinelles Lernen

Rechtzeitig die Ressourcen, die für die Angebotserstellung notwendig sind, mit der benötigten Verfügbarkeit von den Fachbereichen zu bekommen, ist eine Herausforderung im Bid Management. Um die Ressourcen zu schonen und bestmöglich zu nutzen, sind zwei Punkte wichtig. Zum einen, die Aufgaben der Fachkräfte innerhalb der Angebotsabstellung zu reduzieren, zum anderen, die Angebote entsprechend zu priorisieren, um die Ressourcen möglichst gewinnbringend einzusetzen. In beiden Fällen kann maschinelles Lernen Abhilfe schaffen, indem es historische Daten analysiert, Muster erkennt und auf dieser Basis Prognosen ableitet.

Kostenschätzung und Risikobewertung

Für Aufwands- und Risikoprognosen im Angebotsprozess kann ein überwachtetes Lernverfahren zum Einsatz kommen. Hierzu wird ein Modell auf historischen Projektdaten trainiert, in denen Informationen über Kostenschätzungen, tatsächliche Aufwände, und Risikoeinstufungen hinterlegt sind. Man sollte dazu Daten aus früheren Angeboten und

den daraus entstandenen Projekten in einer Datenbank sammeln. Anschließend werden im sog. Feature-Engineering wichtige Einflussfaktoren, wie z. B. Projectscope, Komplexitätsgrad, Kundenbranche etc. extrahiert und in Variablen umgewandelt. Die in Kapitel 2.4.2 beschriebenen Verfahren zur Entscheidungsfindung können verwendet werden, um daraus künftige Aufwandsabschätzungen oder Risiken vorherzusagen. Besonders für Budgetangebote eignet sich eine solche Abschätzung. Budgetangebote sind nicht bindend und haben auf Grund des häufig noch nicht vollständig definierten Scopes eine gewisse Unschärfe. Trotzdem sollten sie so genau wie möglich sein und dem Kunden schnell übermittelt werden, um es ihm zu ermöglichen eine Kaufentscheidung zu treffen oder das benötigte Budget einzustellen. Da bei Budgetangeboten die Kaufentscheidung noch nicht getroffen wurde, sollte ein Unternehmen nicht zu viel Geld und Aufwand in die Erarbeitung eines detaillierten Angebotes stecken, was durch eine ML-generierte Abschätzung gegeben ist.

Priorisierung von Opportunities

Kapitel 3 beschreibt unter anderem, dass es mehrere Meilensteine gibt, die das Verfolgen einer Opportunity auf den Prüfstand stellt. Diese Meilensteine haben den Sinn, die Win-Rate des Unternehmens zu erhöhen. Ressourcen sind wie im Interview mit Experte 1 aufgezeigt endlich. Um die verfügbaren Ressourcen möglichst gewinnbringend einzusetzen, ist eine Priorisierung dieser auf die Angebote mit der höchsten Win-Propability (Gewinnwahrscheinlichkeit) unabdingbar. Je höher die Win-Rate, also die Anzahl an gewonnenen Angeboten im Verhältnis zu den abgegebenen Angeboten, desto besser wurden die Ressourcen bisher eingesetzt. Durch maschinelles Lernen kann aufgezeigt werden, bei welchen Angeboten eine hohe Win-Propability vorherrscht. Diese Win-Propability kann in den Meilensteinen vorgestellt werden und somit entschieden werden, ob einer Opportunity nachgegangen wird oder nicht. Zum Ermitteln der Gewinnwahrscheinlichkeit können historische Daten des Unternehmens oder Marktdaten verwendet werden.

6.4 Aufwandsreduzierung und Qualitätssicherung durch Generative Deep Learning

Ein weiterer Bereich, in dem KI das Bid Management entlasten kann, ist die automatisierte Textgenerierung mittels Generative Deep Learning. Gerade bei umfangreichen Ausschreibungen spart die KI so Zeit und Mühe, in dem sie erste Entwürfe von Texten generiert, die anschließend von Experten überprüft werden. Das reduziert nicht nur

den Aufwand des Bid Managers und der Fachbereiche für die Texterstellung, sondern erhöht auch die Qualität der Texte dadurch, dass mehr Zeit für die Reviews aufgewendet werden kann. Die Funktionsweise ist in Kapitel 2.4.4 beschrieben. Large Language Models sind in der Lage „menschlich“ wirkende Texte zu erstellen. Für das Bid Management liegt der Vorteil vor allem in der Geschwindigkeit und der sprachlichen Konsistenz.

Executive Summaries

Ein Executive Summary ist eine kurze Zusammenfassung der wichtigsten Aspekte und Vorteile eines Angebots, die den Nutzen für den Kunden deutlich macht. Indem es prägnant aufzeigt, warum man sich für dieses Angebot entscheiden sollte, bietet es sowohl eine überzeugende Entscheidungsgrundlage als auch einen Leitfaden für den weiteren Aufbau und Inhalt des Angebots. Daher ist es ein besonders wichtiger Teil des Angebots und auch eine Leitlinie für das Team (APMP 2022b).

LLMs können innerhalb weniger Sekunden eine erste Zusammenfassung zentraler Verkaufsargumente, Projektziele und Mehrwerte erzeugen. Das hilft, Zeit zu sparen und trotzdem ein gut strukturiertes Dokument zu erhalten. Wie Experte 1 aufgeführt hat, werden durch LLMs geschriebene Entwürfe für Executive Summaries oft sprachlich sauberer als eilig geschriebene Drafts.

Wichtig bei der Anwendung ist, dass das LLM sowohl die Anfrage als auch die historischen Daten des Unternehmens kennt. Erst wenn diese in die LLMs eingepflegt wurden, kann ein möglichst korrektes und ansprechendes Executive Summary erstellt werden.

Technische Beschreibungen

Bei standardisierten Produkten oder Modulen kann die KI vorhandene Datenblätter, Dokumentationen und vorherige Angebote einbeziehen, um eine Rohfassung der technischen Beschreibung zu erstellen. Besonders nützlich ist dies, wenn ähnliche Inhalte in vielen Ausschreibungen wiederkehren.

Management Summaries

Neben dem Executive Summary für den Kunden kann ein LLM das Angebot in zielgruppengerechter Sprache aufbereiten und die notwendigen Key Facts ausarbeiten, um es für ein Management Board ohne oder mit nur geringem technischen Hintergrund

aufzuarbeiten. Dieses Management Summary ist der Kern für Freigaben bei komplexen, großen oder risikobehafteten Angeboten. In großen Unternehmen und Konzernen sind diese Managementfreigaben häufig besonders komplex und benötigen viel Zeit in der Vorbereitung.

In allen Fällen ist wichtig, dass Fachleute die automatisch generierten Texte auf inhaltliche Richtigkeit und Vertragskonformität prüfen. Es dürfen auch keine wichtigen Anforderungen vergessen werden, um eine Abwertung oder im schlimmsten Fall Ausschluss im Vergabeverfahren zu vermeiden.

Nachdem dieses Kapitel die Möglichkeiten der Nutzung von KI im Bid Management ausgearbeitet hat, widmet sich das folgende Kapitel den Herausforderungen und Risiken, die es bei der Implementierung von KI zu beachten gilt.

7 Herausforderungen und Risiken bei der Implementierung von KI im Bid Management

Im Anschluss an die vorgestellten Einsatzmöglichkeiten und Nutzen ist es essenziell, die Herausforderungen und Risiken zu betrachten, die mit der Einführung von KI-Systemen im Bid Management einhergehen. Sowohl aus wissenschaftlicher Literatur als auch aus den Experteninterviews lassen sich kritische Faktoren ableiten, die den Erfolg KI-gestützter Angebote erheblich beeinflussen können. Das Kapitel widmet sich daher den zentralen Punkten Datenqualität, Datensicherheit, Erklärbarkeit und Transparenz von KI-Modellen, inklusive technologischer und organisatorischer Anforderungen, Risiken und Fehlerquellen.

7.1 Datenqualität und Datensicherheit

Daten sind die Grundlage jeder KI-Anwendung: Ob maschinelles Lernen, Deep Learning oder Natural Language Processing, alle Verfahren brauchen korrekte, vollständige und relevante Datensätze, um verlässliche Ergebnisse zu liefern.

Datenqualität

Dementsprechend ist die Datenqualität eine Herausforderung bei der Implementierung von KI im Bid Management. Im Bid Management sind Datenquellen häufig verteilt (z. B. in CRM-Systemen, Projektarchive, Excel-Listen). Dies erschwere eine zentrale Datenhaltung und könne zu Inkonsistenzen führen, wie Experte 1 anmerkt. Ein zentralisiertes und gut gepflegtes Dokumentenmanagement ist daher unabdingbar (SRH Fernhochschule 2025a). Neben der strukturierten Bereitstellung ist auch die Aktualität sowie Verfügbarkeit der Daten ein wichtiger Punkt in der Datenqualität und eine Herausforderung im Bid Management. Damit KI-Modelle aktuelle Markt- oder Preisentwicklungen abbilden können, müssen Datensätze regelmäßig gepflegt werden. Besonders in der Branche Professional Mobile Radio sind solche Daten gut geschützt und nicht frei verfügbar. Die kleine Anzahl an Wettbewerbern führt auch dazu, dass keine großen Mengen an Daten verfügbar sind. Ohne solche Daten sind die Ergebnisse der KI nur bedingt zu verwenden.

Datensicherheit

Ein weiterer wichtiger Punkt im Umgang mit Daten ist die Datensicherheit, insbesondere in Bezug auf Vertraulichkeit. Ausschreibungen enthalten oft vertrauliche Kundeninformationen. Auch Informationen des Unternehmens können besonderen Schutzbedarf haben und sollten nicht in das Internet gelangen. Deshalb sollte bei Cloud-basierten KI-Lösungen sichergestellt werden, dass die Daten sicher verwahrt werden und vor unberechtigten Zugriffen geschützt werden (Dr. Poretschkin 2021, S. 26). Bei öffentlichen Ausschreibungen sind auch besondere Geheimhaltungsgrade nicht selten. Bei Ausschreibungen mit dem Geheimhaltungsgrad „Verschlussache – Nur für den Dienstgebrauch“ oder höher ist der On-Premise-Betrieb von KI-Lösungen zwingend notwendig.

Mangelnde Datenqualität und unzureichende Sicherheitsvorkehrungen können die Ergebnisse von KI-Systemen verfälschen oder im schlimmsten Fall zu Datenschutzverletzungen führen. Daher ist eine frühzeitige strategische Ausrichtung auf Datenmanagement und IT-Sicherheit unverzichtbar.

7.2 Erklärbarkeit und Transparenz von KI-Modellen

Ein zentrales Risiko bei der Einführung von KI-Systemen im Bid Management stellt die sogenannte Black-Box-Problematik dar, die insbesondere bei subsymbolischen oder komplexen Deep-Learning-Verfahren ins Spiel kommt. Hierbei ist oft unverständlich, wie das System zu einer bestimmten Empfehlung oder Vorhersage gelangt. Da die internen Berechnungen innerhalb tiefer neuronaler Netze sehr verschachtelt sind, lassen sich die Entscheidungswege nicht einfach an einer klaren Regel ablesen. Das heißt, ein KI-Modell kann mit sehr hoher Wahrscheinlichkeit z. B. einen Risikowert für ein Angebot prognostizieren, ohne dass selbst Data Scientists genau erklären können, welche Parameterkombination zu dieser Einschätzung führte.

Gerade im Bid Management, wo hohe finanzielle Volumina und komplexe Kundenanforderungen zusammenkommen, ist Transparenz über die herangezogenen Faktoren entscheidend. Stakeholder – sowohl aus dem Management als auch aus den Fachabteilungen – müssen Vertrauen in die Ergebnisse der KI haben, um sie in ihre Entscheidungen einfließen zu lassen. Laut Experte 1 könne eine KI zwar beeindruckend klingende Textentwürfe oder Kostenschätzungen liefern, aber sobald die Herkunft oder

Begründung nicht nachvollziehbar ist, entstünde Skepsis. Dies betrifft sowohl die Validität der Eingaben als auch die ethische Frage, ob die KI beispielsweise bestimmte Kunden oder Marktsegmente unbewusst benachteiligt.

Besonders in sicherheits- oder vertrauenssensiblen Branchen, wie etwa dem Verteidigungssektor oder bei staatlichen Beschaffungen, verlangen Auditoren und Auftraggeber zunehmend Erklärbarkeit. Hier reicht es nicht, lediglich eine Zahl oder eine Kennziffer zu präsentieren. Die Verantwortlichen möchten wissen, wie die KI zu dieser Zahl kommt und ob diese Logik gegebenenfalls auf verzerrten Daten oder fehlerhaften Annahmen beruht (Selbst/Powles 2017). Gleichzeitig kann die Black-Box-Problematik zu einer Verzögerung in der Akzeptanz führen, weil Entscheidungsträger befürchten, die Kontrolle über den Prozess zu verlieren.

Wichtig, um der Black-Box-Problematik und der fehlenden Transparenz zu begegnen, ist es daher, Prozessmaßnahmen wie Prüfverfahren einzuführen. Insbesondere bei kritischen Entscheidungen, z. B., ob ein Angebot erarbeitet beziehungsweise abgegeben wird oder nicht, kann man das KI-Urteil durch menschliche Expertise validieren. Hier sind die Erfahrungen langjähriger Bid Manager entscheidend, um die Plausibilität des KI-Outputs zu bewerten, wie auch Experte 2 klarstellt. Das Gleiche gilt bei Texten, die durch KI erstellt werden. Diese gilt es ebenso durch Experten zu reviewen und zu validieren.

Außerdem liefert eine KI, die speziell auf die Anforderungen eines Unternehmens oder eines Sektors trainiert wurde, in der Regel verlässlichere Ergebnisse als ein „Allzwecksystem“. Je passgenauer das System entwickelt wurde, desto eher werden Entscheider die Ergebnisse akzeptieren, weil die KI die typische Terminologie und Historie des Unternehmens kennt.

Um eine möglichst hohe Akzeptanz im Unternehmen herzustellen, sollte jede in den Bid-Prozess eingebundene KI durch Handbücher oder Wikis dokumentiert sein, in denen grundlegende Funktionsweisen, Datenquellen und Einschränkungen beschrieben werden. Dies fördert das Verständnis und steigert die Offenheit gegenüber automatisierten Vorschlägen.

7.3 Technologische und organisatorische Anforderungen

Der erfolgreiche Einsatz von KI im Bid Management berührt nicht nur die technische Infrastruktur, sondern auch die Arbeitsabläufe und Mitarbeiterkompetenzen. Dabei reicht es längst nicht aus, ein KI-System isoliert zu implementieren: Es müssen im Unternehmen neue Strukturen geschaffen oder bestehende an die Anforderungen intelligenter Anwendungen angepasst werden. Fehlende oder unzureichende Vorbereitungen in diesen Bereichen können dazu führen, dass selbst vielversprechende KI-Projekte scheitern.

Performance und Skalierbarkeit

Eine wesentliche Herausforderung besteht darin, die technischen Ressourcen, die KI-Anwendungen, insbesondere bei rechenintensiven Verfahren wie Deep Learning, benötigen, zur Verfügung zu stellen. Unternehmen haben oft weder die Ressourcen noch das Geld, um diese zu implementieren oder zuzukaufen (Mittelstand-Digital 2020, S. 16 f). Hier kann es nötig sein, Cloud-Dienste einzusetzen, damit Trainings- und Rechenprozesse nicht unverhältnismäßig lange dauern. In vielen Fällen empfiehlt sich ein hybrider Ansatz, bei dem lokale Ressourcen für sicherheitsrelevante Daten verwendet werden, während unkritische Prozesse in die Cloud ausgelagert werden.

Systemanbindung und Integration

Damit Daten automatisiert fließen können, ist eine reibungslose Anbindung an bestehende Systeme wie CRM, ERP und Dokumentenmanagement essenziell. Wenn KI-Modelle separat laufen und immer wieder manuell gefüttert werden müssen, verzögert sich der gesamte Proposal-Prozess. Eine API-basierte Integration oder standardisierte Schnittstelle sorgen dafür, dass etwa Kundendaten, Angebotsdokumente und Projekthistorien kontinuierlich in die KI-Anwendungen einfließen (Qymatix 2025).

Digitale Kompetenz der Mitarbeiter

In beiden Interviews wird betont, dass das Verständnis für die Funktionsweise und Grenzen von KI ein Schlüsselfaktor dafür ist, ob neue Lösungen akzeptiert und richtig genutzt werden. Im Gegenzug dazu wurde auch betont, dass beide noch nicht viel Erfahrung mit KI haben und sie daher keine besondere Kenntnis in diesem Bereich haben. In einem Unternehmen ist davon auszugehen, dass sich viele Mitarbeiter nicht

besonders mit dem Thema KI auseinandergesetzt haben, was daher eine Herausforderung für die Implementierung darstellt. Schulungen und Trainings für die Mitarbeiter, die mit KI arbeiten sollen, sind daher unabdingbar.

Data Literacy

Eng mit der Digitalen Kompetenz verbunden ist die Fähigkeit, Daten zu verstehen und angemessen zu verarbeiten, die sogenannte Datenkompetenz (Data Literacy). Dazu gehört es, simple Datenbereinigungen vornehmen zu können, Bias zu erkennen oder zu wissen, wenn Daten veraltet sind und ein Modell nachtrainiert, werden muss. Wenn Mitarbeiter selbst den Wert und die Risiken fehlerhafter Daten kennen, steigt die Qualität sämtlicher KI-Outputs. Diese Data Literacy kann durch Schulungen und Workshops gefördert werden (Litzel/Luber 2019).

Neue Rollen und Teamstrukturen

Eine tiefgehende Implementierung von KI erfordert oftmals neue Rollenverteilungen innerhalb eines Unternehmens. Neben klassischen Positionen wie im Bid Management den Bid Manager und den Pricing Manager entstehen Rollen wie Data Scientist, Data Governance Specialits oder Ethical AI Officer (Höllbacher 2025).

Auch werden sich bestehende Rollen verändern. So wird die Rolle des Bid Managers laut Experte 1 mehr Zeit für strategische und qualitativ anspruchsvolle Tätigkeiten aufwenden können und müssen. Diese Wandlung stellt zwar grundsätzlich eine positive Veränderung der Rolle da, kann allerdings trotzdem Unsicherheiten erzeugen, weshalb ein gut geplantes Change-Management notwendig ist.

7.4 Sonstige Risiken und Fehlerquellen

Neben den bereits erwähnten Herausforderungen gibt es noch weitere Fallstricke, die den Einsatz von KI im Bid Management empfindlich stören können. Diese Risiken sind oft enger mit betrieblichen Abläufen oder personellen Faktoren verknüpft als mit rein technischen Fragestellungen. Der folgende Abschnitt beleuchtet daher mögliche Stolpersteine, die in der Praxis zu spürbaren Fehlentwicklungen führen können.

7.4.1 Abweichung zwischen Modellprognosen und realen Projektanforderungen

Selbst wenn Daten und IT-Systeme ausgereift sind, kann eine KI jederzeit Fehlprognosen abgeben, weil sie die spezifischen Projektanforderungen nicht genügend „ver-

steht“. Im Bid Management sind Ausschreibungen häufig einmalig und hochgradig individualisiert. Zudem können sich technische Spezifikationen rasch ändern, etwa wenn ein Kunde kurzfristig neue Anforderungen einbringt. Das KI-Modell greift dann möglicherweise auf ältere Datenmuster zurück, die in der aktuellen Situation gar nicht mehr passen. Dadurch entstehen Diskrepanzen zwischen der ML-basierten Empfehlung und dem tatsächlichen Projektbedarf, was zu kostspieligen Angebotsspannen führen kann.

Experte 1 weist darauf hin, dass ausschreibungsspezifische Sonderszenarien in der Historie oft unterrepräsentiert seien. Wenn die KI diese Sonderszenarien nicht erkennt, überschätzt oder unterschätzt sie wichtige Variablen wie Zeitbedarf oder Materialkosten.

7.4.2 Fehlprognosen und mangelnde Validierung

KI, insbesondere Deep-Learning-Modelle haben, vor allem bei mangelnder Validierung ein Potenzial für Fehler. Mögliche Ursachen hierfür sind im Folgenden beschrieben.

Bias in Modellen

Wenn KI-Systeme, insbesondere Deep-Learning-Systeme, auf historischen Daten trainiert werden, kann sich vorhandenes menschliches Verhalten oder organisatorische Verzerrungen in den Modellen widerspiegeln. Fehlt es an ausreichender Erklärbarkeit, bleiben solche Biases oft lange unentdeckt (Molnar o. J., S. 17). Ein KI-System könnte beispielsweise jahrelang bei der Bid-/ No-Bid-Entscheidung bestimmte Kundengruppen bevorzugen, ohne dass das Bid-Team bemerkt, dass diese Voreingenommenheit aus veralteten oder einseitigen Trainingsdaten resultiert. Für Stakeholder ist das Vertrauen in die KI schnell erschüttert, wenn die Ergebnisse als unsachlich wahrgenommen werden. Durch regelmäßige Audits oder manuelle Gegenprüfungen sollte untersucht werden, ob ein Bias erkennbar ist.

Overfitting

Tiefe neuronale Netze sind anfällig für Overfitting, das Problem, dass ein Modell zu stark an die Trainingsdaten angepasst ist. Es lernt dabei nicht nur die relevanten Muster und Zusammenhänge, sondern auch das Rauschen und die irrelevanten Details in den Trainingsdaten (Schurr 2025). Es merkt sich also Details und Ausreißer aus der

Vergangenheit, ist aber nicht mehr verallgemeinerungsfähig für neue Ausschreibungen. Wird ein solches Modell ungeprüft eingesetzt, können Prognosen über Zeitplan, Budget oder Gewinnwahrscheinlichkeit komplett daneben liegen, was zu folgenschweren Fehlentscheidungen im Bid-Prozess führt. Um dem entgegenzuwirken, sollte man KI vor der Einführung und auch anschließend regelmäßig auf unterschiedlichen Datensätzen testen und manuelle Stichproben durch erfahrene Bid Manager durchführen.

Underfitting

Tiefe neuronale Netze können neben Overfitting auch von Underfitting betroffen sein, einem Zustand, bei dem das Modell zu einfach ist, um die zugrundeliegenden Muster in den Trainingsdaten zu erfassen. Das Modell bleibt dadurch unzureichend an die vorhandenen Strukturen angepasst und erzielt sowohl auf den Trainings- als auch auf neuen Daten eine schlechte Leistung. Underfitting bedeutet demnach, dass die KI wichtige Abhängigkeiten nicht erkennt und dadurch unzuverlässige Prognosen liefert. Ein solches Modell ist für die operative Nutzung wenig geeignet, da seine Prognosen zu ungenau bleiben. Um Underfitting zu vermeiden, sollten Modelle sorgfältig kalibriert werden: Dazu gehört die Wahl einer geeigneten Modellkomplexität, die Auswahl relevanter Merkmale sowie eine ausreichende Trainingsdauer auf gut aufbereiteten Datensätzen (Schurr 2025).

Übertragungsfehler

Übertragungsfehler entstehen, wenn KI-Vorschläge ungeprüft in die Praxis übernommen werden. RPA-Bots können diese fehlerhaften Inputdaten oder Prognosen noch beschleunigt in Dokumente und CRM-Systeme kopieren, womit sich einzelne Irrtümer schnell zu einer ganzen Kette von Folgefehlern auswachsen (Wright/Witherick/Gordeeva 2017). Damit wird zwar viel Zeit eingespart, zugleich wächst jedoch das systemische Risiko einer Massenverbreitung falscher Daten. Das Beheben solcher Fehler wiederum ist sehr zeitaufwendig.

7.4.3 Personelle und organisatorische Widerstände

Nicht zu unterschätzen sind menschliche Faktoren, die den KI-Einsatz ausbremsen. Viele Bid Manager und Fachleute haben langjährige Erfahrung und eine gewisse Expertise in ihrem Spezialgebiet. Entstehen Unsicherheiten, ob KI-Ergebnisse wirklich besser sind als die „bewährte“ Methode, kann eine Abwehrhaltung resultieren. Fehler,

die durch Overfitting oder Bias entstehen, können diese Abwehrhaltung noch verstärken. Mitarbeitende könnten das Gefühl haben, die Automatisierung würde ihre eigene Kompetenz infrage stellen oder ihre Position im Unternehmen gefährden. Ein unzureichendes Change-Management verschärft diese Problematik, denn ohne interne Kommunikation werden KI-basierte Neuerungen häufig als bedrohliche „Black-Box-Lösung“ wahrgenommen, die das Fachwissen der Teams nicht würdigt (Allganize 2024).

Konfliktpotenzial entsteht zudem, wenn KI-Modelle in kurzer Zeit sehr viele Angebote oder Änderungen generieren und das Team im Anschluss „hinterherräumen“ muss, weil bestimmte Aspekte nicht korrekt abgebildet wurden. Experte 1 berichtet, dass dies bei kleinen Pilotprojekten zwar noch beherrschbar war, bei großen Projekten jedoch zu einem Glaubwürdigkeitsverlust der KI führen kann, falls mehrfach Korrekturrunden nötig sind.

7.4.4 Fehlendes Monitoring

In vielen Unternehmen wird ein KI-System eingeführt, aber es fehlt an Real-Time-Monitoring, das überprüft, ob die Vorhersagen tatsächlich weiterhin stimmen. Märkte sind dynamisch und neue Wettbewerber können in den Markt eintreten, Materialien oder Löhne sich verteuern. Wenn ein KI-Ansatz statisch bleibt und nicht kontinuierlich mit aktualisierten Daten trainiert wird, sind Fehlprognosen fast vorprogrammiert. Eine bestimmte Zeit lang können die Ergebnisse noch gut sein, doch sobald sich die Rahmenbedingungen stark verändern, „altert“ das Modell und seine Qualität sinkt.

Kritisch wird es, wenn keine Mitigation vorgesehen ist. Gibt es im Notfall niemanden, der die KI-Resultate manuell validiert, kann ein einzelner Datenfehler umfassende Konsequenzen nach sich ziehen, sei es ein falsch bepreistes Angebot oder eine Fehleinschätzung von Ressourcen. Ein ausgereiftes Risikomanagement sollte daher genau regeln, wer im Team bei auffälligen oder ungewöhnlichen Prognosen eingreift und wie eine Umstellung auf manuelle Prozesse erfolgen kann, falls die KI ausfällt.

Die Implementierung von KI im Bid Management kann erheblich zur Effizienz und Qualitätssteigerung beitragen, birgt jedoch auch vielfältige Risiken und Herausforderungen, die dieses Kapitel erarbeitet und beschrieben hat. Unternehmen sollten diese Punkte bereits in der Planungsphase berücksichtigen, um negative Konsequenzen zu

minimieren und die Potenziale von KI im Bid Management bestmöglich zu nutzen. Das folgende Kapitel beschreibt, wie man dies gestalten kann.

8 Handlungsempfehlungen für die Implementierung von KI im Bid Management

Nach der Analyse der Herausforderungen im Bid Management in Kapitel 5.4, der Möglichkeiten der Implementierung von KI in Kapitel 6 und der Herausforderungen und Risiken bei der Implementierung von KI in Kapitel 7, werden nun konkrete Handlungsempfehlungen für eine erfolgreiche Einführung von KI im Bid Management vorgestellt. Diese basieren auf den gewonnenen Erkenntnissen, wie etwa dem identifizierten hohen Zeitdruck, unklaren Anforderungen und Ressourcenproblemen im Bid-Prozess, sowie den Vorteilen und Herausforderungen der KI-Nutzung. Um alle relevanten Aspekte abzudecken, orientieren sich die folgenden Handlungsempfehlungen am strategischen Rahmen der Business Modell Generation nach Osterwalder (Osterwalder/Pigneur/Clark 2010). Wiebke Reim, Josef Astrom und Oliver Eriksson haben mittels Literaturrecherche eine Roadmap für die Implementierung von Künstlicher Intelligenz im Rahmen von Business Model Innovation ausgearbeitet (Reim/Åström/Eriksson 2020). Diese Roadmap besteht aus vier Phasen vom anfänglichen Verständnis von KI bis hin zu Akzeptanz.

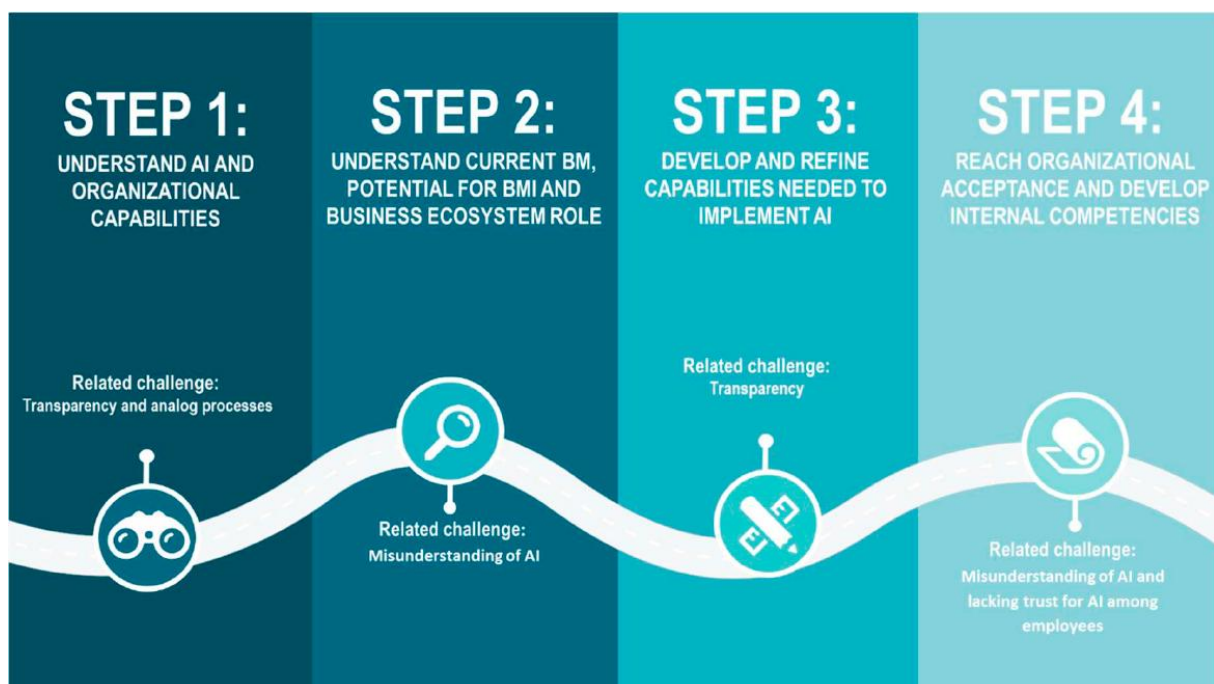


Abbildung 6: Roadmap zur Implementierung von AI (Reim/Åström/Eriksson 2020)

Osterwalder beschreibt in seinem Buch Business Model Generation, dass sich die Geschäftsmodellgeneration auch auf die Kernprozesse einer Abteilung anwenden lassen (Osterwalder/Pigneur/Clark 2010). Durch die Anlehnung dieser, wird sichergestellt,

dass sowohl strategische und prozessuale Aspekte als auch technologische und personelle Faktoren berücksichtigt werden. Angelehnt an die Roadmap zur KI-Implementierung werden im Folgenden vier Handlungsfelder beleuchtet: Strategische, prozessuale, technologische und personelle Empfehlungen.

8.1 Strategische Handlungsempfehlungen

Ein zentrales strategisches Ziel muss es sein, ein tiefgreifendes Verständnis für KI und die erforderlichen organisatorischen Fähigkeiten aufzubauen. Insbesondere das obere Management sollte frühzeitig eingebunden werden, um einen konzeptionellen Rahmen für den KI-Einsatz zu entwickeln und die unternehmensinternen Fähigkeiten zu evaluieren. In dieser Phase gilt es zu klären, welche Ressourcen und Kompetenzen vorhanden sind und welche noch aufgebaut werden müssen, damit KI-Projekte gelingen. Die durchgeführten Interviews zeigen, dass vielen Beteiligten noch unklar ist, was KI im Bid Management leisten kann und welche Prozesse sinnvoll automatisiert werden können. Daher sollte die Geschäftsleitung und die Abteilungsleitung des Bid Managements eine klare KI-Vision und Anwendungsfälle definieren, um Orientierung zu bieten.

Darüber hinaus ist es essenziell, den aktuellen Angebotserstellungsprozess zu analysieren, bevor KI-Initiativen gestartet werden. Es sollte verstanden werden, wie im Bid Management gearbeitet wird und an welchen Stellen KI diesen Prozess verbessern kann, um sicherzustellen, dass KI-Einsatz tatsächlich zu einem Mehrwert führt. Strategisch ist zu entscheiden, in welchen Bid-Management-Bereichen KI den größten Nutzen stiften kann, beispielsweise durch maschinelles Lernen für Prognosen (z. B. Gewinnwahrscheinlichkeit) oder Natural Language Processing für die Analyse von Ausschreibungstexten. So kann die KI-Implementierung gezielt dort ansetzen, wo sie im Einklang mit den Unternehmenszielen steht und Vorteile verspricht.

Ein weiterer strategischer Aspekt ist die Betrachtung des Unternehmensökosystems. KI gestützte Transformationen beschränken sich selten auf einzelne Abteilungen, sondern erfolgen häufig auch in den Schnittstellen zu anderen Abteilungen und ggf. auch Kunden und Unterauftragnehmer. Das Bid Management sollte daher seinen Platz in der Unternehmensstruktur genau verstehen, z. B. im Zusammenspiel mit Vertrieb, Projektmanagement oder Top-Management. Nur wenn klar ist, welche Daten, Schnittstellen und Kompetenzen von den beteiligten Abteilungen bereitgestellt werden (oder von

ihnen benötigt werden), kann die KI-Integration erfolgreich sein. In diesem Zusammenhang sollte auch entschieden werden, ob das Bid Management eine Vorreiterrolle im Unternehmen einnehmen möchte oder eher abwartend von den Erfahrungen anderer lernt. Reim et al. betonen, dass Unternehmen entweder als First Mover oder Follower agieren können (Reim/Åström/Eriksson 2020). Das gleiche gilt auch für Abteilungen innerhalb eines Unternehmens, wobei beide Rollen Vor- und Nachteile haben. Diese strategische Entscheidung beeinflusst Tempo und Ausrichtung der KI-Implementierung maßgeblich.

Sobald die KI-Strategie formuliert ist, sollte sie in der Abteilung und im Unternehmen klar kommuniziert werden. Die Belegschaft muss verstehen, wozu und an welcher Stelle im Prozess KI im Bid Management eingesetzt werden soll. Eine transparente Kommunikation, z. B. durch Workshops, verhindert falsche Erwartungen oder Ängste und schafft bereichsübergreifend Verständnis. Insgesamt legt eine fundierte strategische Planung das Fundament dafür, dass KI-Projekte im Bid Management zielgerichtet gestartet werden und langfristig im Einklang mit der Unternehmensstrategie stehen.

8.2 Prozessuale Handlungsempfehlungen

Bevor konkrete KI-Lösungen eingeführt werden, sollte der Bid-Management-Prozess im Detail analysiert und bei Bedarf angepasst werden. Eine Prozessanalyse identifiziert die Schlüsselphasen im Proposal-Management, in denen KI den größten Mehrwert bieten kann. Beispielsweise kann bereits im frühen Prozessabschnitt der Angebotsvorbereitung geprüft werden, welche Routineaufgaben (z. B. Formatierungen oder Vorlagenbefüllung) durch KI automatisiert werden können, um den Bid Managern mehr Zeit für inhaltliche Arbeiten zu verschaffen. Ebenso lässt sich untersuchen, ob durch KI-Datenanalysen durchgeführt werden können. Das kann zum Beispiel durch das Auswerten vergangener Angebote passieren, um Lessons Learned für aktuelle Angebote bereitzustellen. Empfohlen wird, systematisch diejenigen Schritte herauszuarbeiten, die sich für eine Automatisierung oder KI-Unterstützung eignen. Auf dieser Basis kann ein Fahrplan entstehen, der die Teile des Bid-Prozesses priorisiert, bei denen der Einsatz von KI die höchsten Verbesserungspotenziale hat.

Während der Prozessanalyse ist auch eine Risiko- und Chancenbewertung durchzuführen. Dabei werden potenzielle Risiken identifiziert. Diese können Qualitätsprobleme

durch automatische Textgenerierung oder Verzögerungen durch benötigte Datenaufbereitung sein. Auch werden Chancen, z. B. Zeitersparnis oder höhere Angebotsqualität durch Datenauswertung betrachtet. Verschiedene Beispiele für Risiken sind im Kapitel 7.4 beschrieben. Solche Risiken sollten früh erkannt und mit Mitigationen wie definierten Qualitätschecks durch Menschen verknüpft werden, bevor KI implementiert wird.

Auf Prozessebene ist außerdem sicherzustellen, dass die Schnittstellen und Abläufe für den KI-Einsatz geeignet sind. Gegebenenfalls muss der bestehende Proposal-Prozess optimiert oder flexibilisiert werden, um KI-Tools einzubinden. So könnte es z. B. nötig sein, zusätzliche Prozessschritte für Datenaufbereitung oder -validierung einzuführen. Bestimmte Tätigkeiten lassen sich parallelisieren, wenn Künstliche Intelligenz Teilaufgaben übernimmt. Wichtig ist, Standardisierungen voranzutreiben: Je einheitlicher die Eingabedaten (z. B. Ausschreibungsvorlagen, Angebotsbausteine) und Prozessschritte sind, desto leichter lassen sie sich durch KI verarbeiten. Die Interviews haben gezeigt, dass Ausschreibungen oft unterschiedlich strukturiert sind, was die Automatisierung erschwert. Hier kann es sinnvoll sein, interne Templates und Wissensdatenbanken aufzubauen, in denen frühere Angebote und Antworten gesammelt werden. Diese können als Trainingsgrundlage für KI dienen und den Prozess für zukünftige Angebote beschleunigen. Für die Einführung selbst bewähren sich Pilotprojekte, um KI zunächst in kleinem Umfang im Echtbetrieb zu erproben. Ein Pilot im Bid Management könnte z. B. ein begrenzter Test sein, bei dem eine KI-Anwendung die Requirement-Analyse für ein Angebot übernimmt. Die gewonnenen Erkenntnisse aus dem Piloten ermöglichen es, den Prozess weiter zu verfeinern und Anpassungen im Arbeitsablauf vorzunehmen bevor die vollständige Implementierung erfolgt. Gleichzeitig fördern solche Piloten die Akzeptanz, da sie den Nutzen der KI konkret demonstrieren. Schließlich sollte der Bid-Management-Prozess nach KI-Einführung einem kontinuierlichen Verbesserungszyklus unterliegen. Feedback-Schleifen sind einzurichten, in denen alle beteiligten Stakeholder regelmäßig Rückmeldungen geben, wie gut die KI-Unterstützung funktioniert und wo Optimierungsbedarf besteht. Dieser iterative Ansatz stellt sicher, dass die Prozesse laufend an neue Anforderungen angepasst und die Potenziale der KI voll ausgeschöpft werden.

8.3 Technologische Handlungsempfehlungen

Die erfolgreiche Implementierung von KI im Bid Management erfordert eine passende technologische Infrastruktur und Datenbasis. Studien zeigen, dass insbesondere Datenakquise und IT-Infrastruktur Kernfaktoren für den KI-Erfolg sind (Reim/Åström/Eriksson 2020). Daher sollte man frühzeitig in die Fähigkeit investieren, relevante Daten in hoher Qualität zu erfassen und verfügbar zu machen. Überall dort, wo Prozesse aktuell noch analog oder manuell ablaufen, ist eine Digitalisierung anzustreben, um umfassende Daten für KI-Anwendungen sammeln zu können. Beispielsweise könnten historische Angebotsdokumente und Ausschreibungen zentral in einer Wissensdatenbank abgelegt und mit Metadaten versehen werden, sodass ML-Modelle darauf zugreifen können. Eine solide Datenbasis mitigiert das Risiko von „Garbage in, Garbage out“ und erhöht die Verlässlichkeit der KI-Ergebnisse.

Neben Datenmanagement ist auf Integration der KI-Technologie in die bestehende Systemlandschaft zu achten. Viele KI-Anwendungen wie z. B. NLP-Tools oder RPA-Bots müssen in vorhandene CRM-Systeme, Dokumentenmanagement-Systeme und Datenbanken eingebunden werden. Es empfiehlt sich, Schnittstellen (APIs) zu nutzen, damit der Informationsfluss zwischen KI-Modulen und bestehenden Tools reibungslos funktioniert. Zudem sollte die Skalierbarkeit berücksichtigt werden: Wenn zunächst nur ein Pilotprojekt läuft, die KI-Lösung aber künftig für alle Angebote genutzt werden soll, muss die Infrastruktur entsprechend ausbaufähig sein. Strategisch kann hier die Entscheidung zwischen In-house-Entwicklung und dem Einkauf externer KI-Lösungen getroffen werden. Bei externen Tools ist auf Kompatibilität mit den internen Systemen zu achten, bei Eigenentwicklungen muss genügend Know-How für Wartung und Weiterentwicklung vorhanden sein.

Ein kritischer technischer Aspekt ist die Datensicherheit und der Datenschutz. Im Bid Management wird mit vertraulichen Unternehmens- und Kundendaten gearbeitet, sodass KI-Systeme höchsten Sicherheitsanforderungen genügen müssen. Es ist zu entscheiden, ob sensible Daten in Cloud-Services verarbeitet werden dürfen oder ob On-Premise-Lösungen bevorzugt werden, um die Kontrolle über die Daten zu behalten. In einem Interview wurde beispielsweise darauf hingewiesen, dass man Angebotsdaten ungern einer externen KI-Cloud anvertraut und stattdessen interne Lösungen vorziehen würde. Entsprechend sollten Zugriffsbeschränkungen, Verschlüsselungen und Cybersecurity-Maßnahmen integraler Bestandteil der KI-Infrastruktur sein. Darüber

hinaus ist die Transparenz der KI-Modelle ein Thema: Da komplexe Systeme wie neuronale Netze eine Black-Box darstellen können, sollte über technische Lösungen nachgedacht werden, die Erklärbarkeit fördern (z. B. erklärbare KI-Ansätze). Gegebenenfalls sind zusätzliche Monitoring Prozesse und manuelle Checks von erfahrenen Bid Managern einzusetzen, um die Entscheidungen der KI im Nachhinein nachvollziehen zu können. Gerade in kritischen Bereichen des Bid Managements, wo Fehlentscheidungen erhebliche Folgen haben könnten, ist das notwendig.

Abschließend ist zu betonen, dass die Einführung von KI nicht als einmaliges Projekt, sondern als kontinuierlicher Aufbau von Fähigkeiten und kontinuierlicher Verbesserungsprozess gesehen werden muss. Das Unternehmen sollte Kernkompetenzen in den Bereichen Datenmanagement, KI-Entwicklung und IT-Sicherheit aufbauen oder vertiefen, da diese Fähigkeiten das Rückgrat für den langfristigen KI-Einsatz bilden und mit der technologischen Weiterentwicklung Schritt halten müssen. Insgesamt stellen Investitionen in Infrastruktur, Datenqualität und Sicherheit sicher, dass die KI-Systeme im Bid Management leistungsfähig, zuverlässig und vertrauenswürdig arbeiten.

8.4 Personelle Handlungsempfehlungen

Die Einführung von KI im Bid Management kann nur erfolgreich sein, wenn die Mitarbeiter mitgenommen werden und entsprechende Kompetenzen im Unternehmen aufgebaut werden. Ein wesentlicher Schritt ist es, eine Akzeptanz für die neuen KI-Anwendungen zu schaffen. Erfahrungsgemäß besteht bei digitalen Transformationen das Risiko von Widerstand in der Belegschaft. Egal ob aus Sorge vor Arbeitsplatzverlust oder aufgrund mangelnden Vertrauens in die Technik. Dem sollte aktiv begegnet werden, indem frühzeitig Change-Management-Maßnahmen ergriffen werden. Zum einen sollten die Vorteile der KI klar kommuniziert und erlebbar gemacht werden. Wie in den Interviews betont, verschafft KI den Bid Teams Entlastung bei Routineaufgaben, so dass mehr Zeit für wertschöpfende Tätigkeiten bleibt. Zum anderen sollten Mitarbeiter Ängste adressieren können. Das kann beispielsweise in Fragerunden oder Workshops, in denen offen über die Rolle der KI gesprochen wird geschehen.

Als Best Practice hat sich im Change Management die Umsetzung von Pilotprojekten mit ausgewählten Mitarbeitern erwiesen. Durch solche Pilotprojekte können KI-Teams gebildet werden, in denen technikaffine Mitarbeiter zusammen mit KI-Experten erste

Anwendungsfälle umsetzen. Die Beteiligten fungieren dann als Multiplikatoren im Unternehmen, die ihr Wissen weitergeben und Erfolge sichtbar machen. Gleichzeitig ermöglichen Piloten, praxisnah Schulungsbedarf zu ermitteln. Schulungen und Weiterbildungen sind ein weiterer zentraler Faktor: Es sollten umfassende Trainings angeboten werden, um die Kompetenzen im Umgang mit KI-Systemen zu erhöhen. Dies betrifft insbesondere die Bid Manager, die zukünftig mit der KI arbeiten sollen. Schulungen sollten sowohl Grundwissen über KI vermitteln als auch die konkrete Anwendung der neuen Bid-Management-Tools einüben.

Neben formalen Trainings ist die förmliche und informelle Zusammenarbeit zu fördern. Zum einen kann es hilfreich sein, interdisziplinäre Teams zu etablieren, in denen IT-Experten, Bid Manager und eventuell sogar Data Scientists gemeinsam an den Verbesserungen der KI arbeiten. Zum anderen sollten Feedback-Kanäle geschaffen werden, damit Mitarbeiter ihre Erfahrungen mit den neuen Prozessen rückmelden können. Ein kontinuierlicher Austausch in regelmäßigen Meetings hilft, frühzeitig Probleme zu erkennen und Verbesserungsvorschläge aufzunehmen. Reim et al. empfehlen explizit, Feedback-Schleifen zwischen allen beteiligten Parteien (inklusive den beteiligten Abteilungen und sonstigen Stakeholdern) zu institutionalisieren, um kontinuierlich aus der Anwendung zu lernen (Reim/Åström/Eriksson 2020). Dieses Feedback ist wertvoll, um interne Kompetenzen immer weiter auszubauen und sicherzustellen, dass das erworbene Wissen aktuell bleibt.

Schließlich sollte die Kollaboration mit externen Partnern nicht vernachlässigt werden. Durch Kooperationen, zum Beispiel mit Beratungsunternehmen, KI-Anbietern oder Forschungseinrichtungen kann das Unternehmen seine Lernkurve steiler gestalten und Akzeptanz bei allen Stakeholdern fördern. Externe Partner können Best Practices einbringen und helfen, die Belegschaft für neue Ideen zu öffnen. Zusammenfassend lässt sich sagen, dass eine offene, lernbereite und gut informierte Belegschaft der Schlüssel ist, um KI erfolgreich und nachhaltig im Bid Management zu verankern. Indem Mitarbeiter befähigt und beteiligt werden, stellt das Unternehmen sicher, dass KI nicht nur technisch, sondern vor allem menschlich Einzug in die Angebotserstellung hält. Als anerkanntes Hilfsmittel zur Verbesserung der Angebotsprozesse und zur Steigerung der Win-Rate.

9 Fazit

Abschließend lässt sich festhalten, dass die vorliegende Arbeit wesentliche Erkenntnisse zur Implementierung von KI im Bid Management geliefert hat. Im Kern stehen die Herausforderungen im Bid Management und die Frage, wie Künstliche Intelligenz helfen kann, diese zu bewältigen. Die Analyse hat gezeigt, dass Bid Management ein komplexer Prozess mit hohem Zeitdruck, begrenzten Ressourcen und erheblichem Koordinationsaufwand ist. Häufig müssen Bid Manager unter engen Deadlines Angebote erstellen, während Fachwissen aus verschiedenen Abteilungen zusammengezogen wird. Zudem sind Kundenanforderungen in Ausschreibungen oft unklar oder uneinheitlich formuliert, was intensive Abstimmung und Qualitätssicherung erfordert. Weiterhin erhöht starker Wettbewerbsdruck den Anspruch, Angebote nicht nur fristgerecht und technisch passend, sondern auch überzeugend, auf die Hot-Buttons des Kunden zugeschnitten und kosteneffizient zu gestalten. Diese Herausforderungen unterstreichen den Bedarf nach innovativen Lösungen und zeigen gleichzeitig die Potenziale von KI im Bid Management auf.

Die Arbeit verdeutlicht, dass KI-Methoden wie Natural Language Processing, Robotic Process Automation und maschinelles Lernen sowie generative KI-Modelle eine Reihe von konkreten Einsatzmöglichkeiten im Angebotsprozess bieten. So kann NLP dabei helfen, umfangreiche Ausschreibungsdokumente automatisiert zu analysieren und relevante Informationen herauszufiltern. Beispielsweise lassen sich damit Anforderungen und Schlüsselbegriffe (z. B. „Muss-/Soll-Kriterien“ in öffentlichen Ausschreibungen) schnell identifizieren und hervorheben. Dadurch wird die Anforderungsanalyse präziser und es wird sichergestellt, dass keine wichtigen Vorgaben übersehen werden. RPA wiederum eignet sich, um repetitive manuelle Tätigkeiten zu automatisieren, was dem Zeitdruck entgegenwirkt. In der Praxis könnten RPA-Bots etwa Daten aus Ausschreibungen oder CRM-Systemen direkt in Angebotsvorlagen einpflegen, standardisierte Textbausteine zusammenstellen oder Formulare und Tabellen mit Kunden- und Produktinformationen füllen. Selbst Genehmigungsprozesse im Rahmen der Angebotserstellung ließen sich mit RPA unterstützen, indem Dokumente automatisch an die richtigen Stellen weitergeleitet und Freigaben nachverfolgt werden. Dadurch werden Teams von Routinearbeiten entlastet und gewinnen Zeit für strategische Aufgaben. Auch maschinelles Lernen zeigt großes Potential im Bid Management, besonders in der Entscheidungsunterstützung und Prognosen. Mithilfe überwachter Lernverfahren

können Modelle trainiert werden, um auf Basis historischer Projektdaten Aufwände, Kosten und Risiken neuer Angebote abzuschätzen. Die Arbeit hat herausgestellt, dass beispielsweise ML-Modelle genutzt werden können, um eine präzise Aufwandsschätzung für ein Angebot abzugeben oder Risikofaktoren frühzeitig zu erkennen. Dies ist insbesondere bei der Erstellung von Budgetangeboten hilfreich, bei denen noch unvollständige Informationen vorliegen. Ein datengetriebenes Modell kann hier schnell eine erste Einschätzung liefern, sodass die Vertriebsmitarbeiter zügig auf Kundenanfragen reagieren können. Ebenso kann ML die Priorisierung von Opportunities verbessern, indem es die Gewinnwahrscheinlichkeit (Win Probability) für einzelne Angebote vorhersagt. So kann das Unternehmen besser entscheiden, auf welche Opportunities es ihre begrenzten Ressourcen fokussieren sollte. Insgesamt ermöglichen solche ML-Anwendungen eine fundiertere Entscheidungsfindung im Angebotsprozess. Schließlich wurde in der Arbeit der Einsatz von generativer KI (insbesondere Large Language Modells) für die automatisierte Textgenerierung untersucht. Gerade in zeitkritischen Phasen kann KI erste Textentwürfe von Angebotsteilen z. B. Executive Summaries oder technische Beschreibungen erstellen. Diese großen Sprachmodelle sind inzwischen in der Lage, verständliche und kontextgerechte Texte zu formulieren, wodurch sich die Erstellung aufwendiger Dokumentabschnitte erheblich beschleunigen lässt, ohne dass die sprachliche Qualität leidet. Zum Beispiel, könnte ein LLM binnen Sekunden einen gut strukturierten Entwurf eines Executive Summary liefern, der dann von den Experten des Bid Teams inhaltlich geprüft und verfeinert wird. So bleibt mehr Zeit für die inhaltliche Prüfung und Feinabstimmung, während stilistische Konsistenz und Grundstruktur bereits von der KI vorbereitet werden. Wichtig ist dabei natürlich, wie bereits erwähnt, dass menschliche Experten die KI-Outputs prüfen. Automatisch generierte Texte müssen auf inhaltliche Richtigkeit, Vollständigkeit und Vertragskonformität validiert werden, um Fehler oder Auslassungen auszuschließen. Mit diesem menschlichen Quality-Check kombiniert, kann generative KI dennoch eine erhebliche Zeitersparnis und Qualitätsverbesserung bewirken.

Aufbauend auf diesen Ergebnissen wurden in der Arbeit auch Handlungsempfehlungen formuliert, um das Potenzial der KI gezielt zu nutzen. Es zeigte sich, dass eine schrittweise Einführung von KI im Bid Management zu empfehlen ist. Unternehmen sollten zunächst Pilotprojekte in identifizierten Problemfeldern durchführen, um Erfahrungen zu sammeln. Parallel dazu ist auf Datenqualität und Wissensmanagement zu

achten, damit KI-Systeme mit verlässlichen Informationen arbeiten können wie beispielsweise gepflegte Dokumentation und zentrale Wissensdatenbanken für vergangene Angebote. Strategisch wird empfohlen, klare Ziele und Anwendungsfälle für KI zu definieren, statt unstrukturiert einem Technologietrend zu folgen. KI sollte dort implementiert werden, wo konkreter Mehrwert in Form von Effizienzsteigerung zu erwarten ist. Prozessanpassung sind sorgfältig zu planen, damit KI-Tools nahtlos in die bestehenden Abläufe integriert werden und ihre Ergebnisse von den Teams auch angenommen und weiterverarbeitet werden können. Darüber hinaus betont die Arbeit Change-Management-Aspekte. Um Akzeptanz für KI im Bid Team zu schaffen und Ablehnung entgegenzuwirken, ist eine frühzeitige Einbindung und Schulung der Mitarbeiter essenziell. Die Mitarbeiter sollten die Funktionsweise der eingesetzten KI verstehen, damit sie deren Ergebnisse einschätzen und sinnvoll nutzen können. Insgesamt liefern diese Empfehlungen praxisnahe Leitlinien, um Stolpersteine bei der KI-Implementierung zu vermeiden und die Digitalisierung des Bid Managements erfolgreich voranzutreiben.

Angesichts dieser Möglichkeiten durch KI widmet sich die Arbeit auch der Beantwortung der Forschungsfrage, die im Einleitungskapitel formuliert wurde. Diese lautete: *„Welche Möglichkeiten gibt es, Künstliche Intelligenz im Bid Management zu implementieren, und welche Aufgaben können dabei durch KI im Angebotsprozess unterstützt oder übernommen werden?“* Basierend auf den Ergebnissen kann diese Frage wie folgt beantwortet werden: Es gibt eine Bandbreite an KI-Methoden, die im Bid Management implementiert werden können. Von regelbasierten Ansätzen und RPA über maschinelles Lernen bis hin zu fortgeschrittener NLP und generativer KI. Diese Technologien ermöglichen es, verschiedene Aufgaben im Angebotsprozess zu automatisieren oder intelligent zu unterstützen. Konkret können Analysen wie das Auswerten von Ausschreibungsunterlagen oder das Herausfiltern relevanter Anforderungen durch NLP-Systeme schneller und zuverlässiger erledigt werden als manuell. Routinearbeiten und administrative Vorgänge, wie beispielsweise Datentransfers zwischen Systemen, Formatierungen, Aktualisierung von Dokumentenständen lassen sich mittels RPA vollständig automatisieren. Entscheidungsvorbereitende Aufgaben, etwa die Abschätzung von Projektaufwänden, Kosten und Risiken oder die Bewertung der Erfolgsaussichten eines Angebots, können durch ML-Modelle unterstützt werden, die Muster in historischen Daten erkennen und Prognosen ableiten. Schließlich können kreative Textaufgaben, vom Formulieren erster Angebotsentwürfe über Zusammenfassungen

bis hin zur Erstellung von Executive Summaries, durch generative KI übernommen oder zumindest vorbereitet werden. All diese Ansätze entlasten das Bid Management Team von zeitintensiven oder komplexen Teilaufgaben und erlauben es den menschlichen Experten, sich stärker auf strategische Planung, Kundenkommunikation und Feinabstimmung der Angebotsinhalte zu konzentrieren. Zusammenfassend kann KI im Bid Management überall dort implementiert werden, wo große Datenmengen, wiederkehrende Prozesse oder Standardisierungen vorliegen, und genau in diesen Bereichen unterstützt KI dann Aufgaben, die bisher manuell bewältigt wurden. Die Arbeit hat somit aufgezeigt, dass es vielfältige Möglichkeiten gibt und dass damit ein erheblicher Teil des Angebotsprozesses durch KI unterstützt werden kann, ohne die letztendliche Kontrolle durch erfahrene Bid Manager zu ersetzen.

Trotz dieser Ergebnisse muss kritisch auf die Limitationen der Arbeit hingewiesen werden. Ein zentrales Hindernis bei der Forschung war die eingeschränkte Verfügbarkeit von wissenschaftlich fundierter Literatur zum Thema KI im Bid Management. Da es sich um ein neues Feld innerhalb des Bid Managements handelt, existieren bislang kaum umfassende akademische Studien oder etablierte Theorien dazu. Viele der verfügbaren Quellen erwiesen sich als entweder sehr technisch (etwa detaillierte KI-Fachpublikationen ohne Bezug zur Management-Praxis) oder als populärwissenschaftlich bzw. marketinggetrieben. Insbesondere Unternehmens-Whitepaper und Blogbeiträge propagieren zwar den Einsatz von KI im Bid Management, liefern jedoch oft keine belastbaren empirischen Daten oder unabhängigen Analysen. Zudem fehlten in der Literatur kohärente Definitionen für zentrale Begriffe: die verschiedenen Bereiche innerhalb der KI sind wissenschaftlich nicht einheitlich definiert, was den Vergleich verschiedener Quellen erschwerte. Diese Lücken in der Literatur machten es notwendig, viele Grundlagen selbst herzuleiten und Definitionen aus verschiedenen Quellen zu kombinieren. Die geringe Anzahl der verfügbaren Publikationen mit Management-Fokus bedeutete auch, dass einige Annahmen aus allgemeinen KI-Implementierungsstrategien übernommen werden mussten, anstatt auf explizite Studien im Bid Management zurückgreifen zu können. Insgesamt limitieren diese Faktoren die Generalisierbarkeit der Ergebnisse. Die gewonnenen Erkenntnisse stellen einen ersten explorativen Einblick dar, sollten jedoch mangels breiter empirischer Validierung mit gewisser Vorsicht interpretiert werden. Hier besteht ein deutlicher Forschungsbedarf. Allerdings ist der Bereich des Bid Management eine Nische innerhalb der der Geschäftsprozesse, weshalb die Forschung in diesem Bereich keine Priorität zu haben scheint.

Zusätzlich zu den inhaltlichen Grenzen der Literatur zeigen sich methodische Limitationen in der Durchführung der Experteninterviews. Insbesondere bei der Interpretation der Interviewergebnisse ist zu berücksichtigen, dass die befragten Experten aus dem Bid Management nur begrenztes Vorwissen zu KI mitbrachten. In den geführten Experteninterviews wurde deutlich, dass die Gesprächspartner zwar über umfangreiche Erfahrung im Angebotsprozess verfügten, jedoch mit den Möglichkeiten moderner KI-Technologien nicht vertraut waren. Dies führte dazu, dass konkrete KI-Anwendungsfälle im Gespräch nur begrenzt und oft nur auf einer abstrakten Ebene identifiziert werden konnten. Die Interviewpartner blieben vielfach bei generellen Vorstellungen (z. B. Automatisierung von Routineaufgaben) und es war schwierig, ohne zusätzliche Impulse sehr spezifische oder innovative Einsatzideen aus ihrer Sicht zu erhalten. Rückblickend stellt dies eine Einschränkung dar. Ohne ausreichende KI-Kenntnisse seitens der Experten konnten bestimmte Potenziale nicht voll ausgeschöpft werden. Möglicherweise hätten detailliertere Erklärungen oder kurze Schulungen zu KI vor dem Interview den Teilnehmern geholfen, sich mehr unter den Technologien vorzustellen und kreativer über deren Einsatz nachzudenken. So hätte man im gemeinsamen Dialog tiefer in das Thema KI eintauchen und weitere Anwendungsmöglichkeiten erforschen können, die den Experten zunächst nicht bewusst waren. Diese Erfahrung betont, dass zukünftig eine engere Einbindung der Domänenexperten in das Thema KI sinnvoll ist, um ein gemeinsames Verständnis zu schaffen. Nur so ließe sich das volle Potenzial und auch mögliche Bedenken im Zusammenspiel von KI und Bid Management umfassend ergründen. Trotz dieser Einschränkungen lieferten die Interviews wertvolle praxisnahe Einsichten und bestätigten viele der vermuteten Herausforderungen und Lösungsansätze. Sie zeigten zudem, dass der Faktor Mensch entscheidend dafür ist, wie wirkungsvoll KI im Bid Management zum Tragen kommt.

Zusammenfassend hat die Masterarbeit gezeigt, dass künstliche Intelligenz im Bid Management erhebliche Chancen bietet, den Angebotsprozess effizienter zu gestalten und die Qualität von Angeboten zu steigern. Die wesentliche Forschungsfrage konnte dahingehend beantwortet werden, dass es vielfältige Möglichkeiten gibt, KI zu implementieren, und dass zahlreiche Tätigkeiten im Bid-Prozess durch KI unterstützt oder automatisiert werden können. Gleichzeitig wurde deutlich, dass die Einführung von KI sorgfältige Vorbereitung erfordert. Unternehmen müssen mit Bedacht vorgehen, geeignete Anwendungsfälle auswählen und ihre Mitarbeiter auf diesen Weg mitnehmen.

Die Arbeit leistet hier einen ersten Beitrag, indem sie sowohl praxisrelevante Anwendungsfelder als auch mögliche Stolpersteine und Lösungsansätze aufgezeigt hat. Die Grenzen der Untersuchung, insbesondere die dünne Studienlage und das begrenzte KI-Verständnis der Experten offenbaren, dass dieses Themenfeld noch jung und unerforscht ist. Umso wichtiger ist künftig ein intensiver Wissensaustausch zwischen KI-Fachleuten und Bid-Management-Experten. Nur durch interdisziplinäre Zusammenarbeit lässt sich das volle Potenzial der KI im Bid Management realisieren. Insgesamt untermauern die Ergebnisse jedoch bereits jetzt, dass KI einen entscheidenden nächsten Schritt in der Digitalisierung des Bid Managements darstellen kann, sofern ihre Implementierung strategisch geplant ist und der Mensch als finaler Entscheider eingebunden bleibt.

Literatur

- Allganize (2024): Resistance to AI: Governance and Cultural Challenges. URL: <https://www.allganize.ai/en/blog/resistance-to-ai-governance-and-cultural-challenges> (06.04.2025).
- APMP (2022a): End-to-End Process. URL: <https://apmp.helpjuice.com/manage-processes/end-to-end-process#common-pitfalls-and-misconceptions-9> (01.02.2025).
- APMP (2022b): Executive Summaries. URL: https://apmp.helpjuice.com/focus-on-the-customer/executive-summaries?from_search=182266093 (05.04.2025).
- APMP (2022c): Virtual Team Management. URL: <https://apmp.helpjuice.com/manage-processes/virtual-team-management> (01.02.2025).
- Beierle, Christoph/Kern-Isberner, Gabriele (2019): Methoden wissensbasierter Systeme: Grundlagen, Algorithmen, Anwendungen. 6., überarbeitete Auflage. Auflage. Wiesbaden: Springer Vieweg. DOI: 10.1007/978-3-658-27084-1.
- Blessing, Marvin (2023): AI and Scaling the Compute for the new Moore's Law | Computer Science Blog @ HdM Stuttgart. URL: <https://blog.mi.hdm-stuttgart.de/index.php/2023/03/03/ai-and-scaling-the-compute-for-the-new-moores-law/> (26.01.2025).
- Blouin, Lou (2023): AI's mysterious 'black box' problem, explained. URL: <https://um-dearborn.edu/news/ais-mysterious-black-box-problem-explained> (17.01.2025).
- Bogner, Alexander/Littig, Beate/Menz, Wolfgang (2014): Interviews mit Experten: eine praxisorientierte Einführung. Wiesbaden: Springer VS.
- Brainial (2025): Wirksame Strategien für das Bid Management im Jahr 2024. URL: <https://de.brainial.com/tendermanagement/effective-strategies-for-mastering-bid-management-in-2024> (06.04.2025).
- Deutschlandfunk (2024): Energiehunger durch KI. URL: <https://www.deutschlandfunk.de/atomkraft-akw-ki-energie-100.html> (17.01.2025).
- Dr. Poretschkin, Maximilian (2021): Leitfaden zur Gestaltung vertrauenswürdiger Künstlicher Intelligenz. URL: <https://publica-rest.fraunhofer.de/server/api/core/bitstreams/db24f6ef-c73e-4353-89d5-2b37b3cd82dc/content> (17.04.2025).
- Ertel, Wolfgang (2021): Grundkurs Künstliche Intelligenz: eine praxisorientierte Einführung. 5. Auflage. Auflage. Wiesbaden [Heidelberg]: Springer Vieweg.
- Europäische Union (2025): Artificial Intelligence Act. URL: <https://artificialintelligenceact.eu/de/article/3/> (16.08.2024).
- Faster Capital (2024): Mögliche Nachteile Regelbasierter Systeme Angehen. URL: <https://fastercapital.com/keyword/mögliche-nachteile-regelbasierter-systeme-angehen.html> (27.10.2024).
- Faster Capital (2025): Regelbasierte Systeme Die Regeln aendern Die Flexibilitaet der Fuzzy Logik in regelbasierten Systemen. URL: <https://fastercapital.com/content/Rule-Based-Systems--Bending-the-Rules--The-Flexibility-of-Fuzzy-Logic-in-Rule-Based-Systems.html> (27.10.2024).

- Figuroa-García, Juan Carlos (2017): Applied Computer Sciences in Engineering: 4th Workshop on Engineering Applications, WEA 2017, Cartagena, Colombia, September 27-29, 2017, Proceedings. Cham: Springer International Publishing AG.
- Forum Verlag Herkert GmbH (2019): Prozessoptimierung durch Digitalisierung: Effizienz steigern. URL: <https://www.forum-verlag.com/fachwissen/fuehrung-und-management/prozessoptimierung-digitalisierung/> (06.04.2025).
- Foster, David/Friston, K. J. (2023): Generative deep learning: teaching machines to paint, write, compose, and play. Second edition. Auflage. Beijing ; Boston: O'Reilly.
- Goodfellow, Ian/Bengio, Yoshua/Courville, Aaron (2018): Deep Learning: das umfassende Handbuch: Grundlagen, aktuelle Verfahren und Algorithmen, neue Forschungsansätze. 1. Auflage. Auflage. Frechen: mitp.
- Höllbacher, Lisa (2025): Die neuen Rollen in einer AI-fähigen Organisation: Was IT-Führungskräfte wissen müssen. URL: <https://lsz.at/blog/die-neuen-rollen-einer-ai-faehigen-organisation-was-it-fuehrungskraefte-wissen-muessen> (06.04.2025).
- IBM (2021a): Was ist NLP (Verarbeitung natürlicher Sprache)? URL: <https://www.ibm.com/de-de/topics/natural-language-processing> (26.01.2025).
- IBM (2021b): Was ist ein neuronales Netz? URL: <https://www.ibm.com/de-de/topics/neural-networks> (01.02.2025).
- IBM (2024): Was ist maschinelles Lernen (ML)? URL: <https://www.ibm.com/de-de/topics/machine-learning> (27.10.2024).
- Institute of Data (2023): Exploring the Differences Between Narrow AI, General AI, and Superintelligent AI | Institute of Data. URL: <https://www.institutedata.com/blog/exploring-the-differences-between-narrow-ai-general-ai-and-superintelligent-ai/> (09.04.2025).
- Jung, Alexander (2024): Maschinelles Lernen: Die Grundlagen. 1st ed. 2024. Auflage. Singapore: Springer Nature Singapore. DOI: 10.1007/978-981-99-7972-1.
- Jurafsky, Daniel/Martin, James H. (2025): Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models. 3. Auflage. URL: <https://web.stanford.edu/~jurafsky/slp3> (25.01.2025).
- Kimothi, Abhinav (2024): Embeddings — The Blueprint of Contextual AI. URL: <https://medium.com/the-rag-explorer/embeddings-the-blueprint-of-contextual-ai-e72f6781028f> (25.01.2025).
- Laatupankki (2025): Wie funktioniert kontinuierliche Verbesserung im Kern des Qualitätssystems? - Laatupankki. URL: <https://laatupankki.fi/de/ressourcen/wie-kontinuierliche-verbesserung-im-kern-des-qualitaetssystems-funktioniert> (06.04.2025).
- Lacity, Professor Mary (2016): Paper 16/01 Robotic Process Automation: The Next Transformation Lever for Shared Services.
- Leder, Benedikt (2024): KI birgt großes Potenzial für mehr Automatisierung. URL: <https://www.datev-magazin.de/praxis/it-internet/ki-birgt-grosses-potenzial-fuer-mehr-automatisierung-134546> (06.04.2025).

- Litzel, Nico/Luber, Stefan (2019): Was ist Data Literacy? URL: <https://www.bigdata-insider.de/was-ist-data-literacy-a-823501/> (06.04.2025).
- Luber, Stefan (2024): Was ist subsymbolische KI? URL: <https://www.bigdata-insider.de/was-ist-subsymbolische-ki-a-6005faede043b6898ff51d9365d36391/> (17.04.2025).
- Malla, Naveen (2024): King - Man + Woman = Queen. URL: <https://pub.toward-sai.net/king-man-woman-queen-43e5b33bc7c5> (25.01.2025).
- Matzka, Stephan (2021): Künstliche Intelligenz in den Ingenieurwissenschaften: maschinelles Lernen verstehen und bewerten. Wiesbaden [Heidelberg]: Springer Vieweg.
- McCarthy, John u. a. (2006): A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. In: AI Magazine, Jg. 27 (4). DOI: <https://doi.org/10.1609/aimag.v27i4.1904>.
- Mittelstand-Digital (2020): Künstliche Intelligenz im Mittelstand Potenziale und Anwendungsbeispiele. EffizienzCluster Management GmbH. URL: https://www.mittelstand-digital.de/MD/Redaktion/DE/Publikationen/zentrum-dortmund-ki-im-mittelstand.pdf%3F__blob%3DpublicationFile%26v%3D2.
- Molnar, Christoph (o. J.): Interpretable Machine Learning.
- Newman, Larry (2011): Shipley proposal guide™. Version 4.1. Auflage. Kaysville, UT: Shipley Associates.
- Nikhil (2024): Der Unterschied zwischen maschinellem Lernen und Deep Learning. URL: <https://www.carmatec.com/de/blog/unterschied-zwischen-maschinell-em-lernen-und-deep-learning/> (13.04.2025).
- Osterwalder, Alexander/Pigneur, Yves/Clark, Tim (2010): Business model generation: a handbook for visionaries, game changers, and challengers. Hoboken, NJ: Wiley.
- Pangeanic (2024): Word embeddings : Ein leicht verständlicher Leitfaden. URL: <https://blog.pangeanic.com/de/word-embeddings-ein-leicht-verstandlicher-leitfaden> (25.01.2025).
- Qymatix (2025): CRM-ERP-Integration für Artificial Intelligence – Qymatix KI-Software für den Großhandel Vertrieb. URL: <https://qymatix.de/de/crm-erp-integration-ki/> (13.04.2025).
- Reim, Wiebke/Åström, Josef/Eriksson, Oliver (2020): Implementation of Artificial Intelligence (AI): A Roadmap for Business Model Innovation. In: AI, Jg. 1 (2), S. 180–191. DOI: 10.3390/ai1020011.
- Safar, Milad (2019): RPA-Implementierung - Die 10 größten Herausforderungen. URL: <https://weissenberg-group.de/die-10-groessten-herausforderungen-bei-der-rpa-implementierung/> (01.02.2025).
- Salesforce Inc. (2025): 8 geläufige Beispiele für maschinelle Verarbeitung natürlicher Sprache und ihre Wirkung auf die Kommunikation. URL: <https://www.tableau.com/de-de/learn/articles/natural-language-processing-examples> (26.01.2025).

- Schurr, Philipp (2025): Overfitting und Underfitting im Machine Learning. URL: <https://mindsquare.de/knowhow/overfitting-und-underfitting-im-machine-learning/> (06.04.2025).
- Selbst, Andrew D./Powles, Julia (2017): Meaningful information and the right to explanation. In: International Data Privacy Law, Jg. 7 (4), S. 233–242. DOI: 10.1093/idpl/ix022.
- Simonini, Thomas (2025): The Deep Q-Learning Algorithm - Hugging Face Deep RL Course. URL: <https://huggingface.co/learn/deep-rl-course/en/unit3/deep-q-algorithm> (13.04.2025).
- Singureanu, Constantin (2025): Die 15 wichtigsten RPA-Anwendungsfälle nach Branche. URL: <https://www.zaptest.com/de/top-15-rpa-robotic-process-automation-anwendungsaefaele-nach-branchen-finanzen-gesundheitswesen-hr-buchhaltung-fertigung-mehr> (01.02.2025).
- SRH Fernhochschule (2025a): Big Data und KI: Die Zukunft der Datenanalyse. URL: <https://www.mobile-university.de/digitalisierung/big-data-ki-datenanalyse/> (13.04.2025).
- SRH Fernhochschule (2025b): Maschinelles Lernen: Grundlagen, Anwendungen und Entwicklungen. URL: <https://www.mobile-university.de/studium/machine-learning/> (01.02.2025).
- Wood, Thomas (2020): Große Sprachmodelle (LLM) und NLP: Eine neue Ära der KI und des ML hat begonnen. URL: <https://fastdatascience.com/de/generative-ki/llm-nlp/> (26.01.2025).
- Wright, David/Witherick, Dupe/Gordeeva, Marina (2017): The robots are ready. Are you? Untapped advantage in your digital workforce. Deloitte LLP. URL: <https://www2.deloitte.com/content/dam/Deloitte/cn/Documents/strategy/deloitte-cn-consulting-the-robots-are-ready-en-180329.PDF> (01.02.2025).
- Wuttke, Laurenz (2023): Deep Learning: Was ist es und warum wird es eingesetzt? URL: <https://datasolut.com/was-ist-deep-learning/> (16.01.2025).
- Wuttke, Laurenz (2024): Machine Learning: Algorithmen, Methoden und Beispiele. URL: <https://datasolut.com/was-ist-machine-learning/> (19.10.2024).
- Zweig, Stefan (2023): Was ist Intelligenz? URL: https://phsalzburg.at/wp-content/uploads/2023/01/Was_ist_Intelligenz.pdf.

Abbildungsverzeichnis

Abbildung 1: Klassifizierung Künstlicher Intelligenz (eigene Darstellung).....	8
Abbildung 2: Schemenhafte Darstellung von Reinforcement Learning (eigene Darstellung).	15
Abbildung 3: Schemenhafte Darstellung eines Neuronalen Netzes (IBM 2021b).....	18
Abbildung 4: Schematische Darstellung für Word-Embeddings (eigene Darstellung)	23
Abbildung 5: Business Development Prozess (eigene Darstellung).....	31
Abbildung 6: Roadmap zur Implementierung von AI (Reim/Åström/Eriksson 2020).....	57

Erklärung

Ich versichere, dass ich die vorliegende Abschlussarbeit selbständig angefertigt, nicht anderweitig für Prüfungszwecke vorgelegt, keine anderen als die angegebenen Quellen und Hilfsmittel benutzt, sowie wörtliche und sinngemäße Zitate als solche gekennzeichnet habe und die Überprüfung mittels Anti-Plagiatssoftware dulde.

Ulm, 20.04.2025

Ort, Datum

S. h

Unterschrift

Abkürzungsverzeichnis

A	Aktion (eng. Action)
AI	Artificial Intelligence
ANN	Künstliche Neuronale Netze (eng.: Artificial Neural Networks)
API	Application Programming Interface
APMP	Association of Proposal Management Professionals
BAFO	Best and Final Offer
BD	Business Development
Bert	Bidirection Encoder Representation from Transformers
CEO	Chief Executive Officer
CFO	Chief Financial Officer
CNN	Convolutional Neural Networks
CRM	Customer Relationship Management
DL	Deep Learning
DQN	Deep Q-Networks
Eng.	Englisch
EU	Europäische Union
ERM	Enterprise Ressource Management
GPT	Generative pre-trained Transformer
GUI	Graphische Benutzeroberfläche (eng.: Graphical User Interface)
IT	Informationstechnik
KI	Künstliche Intelligenz
k -NN	k -Nearest-Neighbor
LLaMA	Large Language Model Meta AI

LLM	Large Language Modells
ML	Maschinelles Lernen
NLP	Natural Language Processing
OCR	Optische Zeichenerkennung (eng.: Optical Character Recognition)
PCA	Hauptkomponentenanalyse (eng.: Principal Component Analysis)
R	Belohnung (eng.: Reward)
RFQ	Angebotsaufforderung (eng.: Request for Proposal)
RPA	Robotic Process Automation
S	Zustand (eng.: State)
US(A)	United States (of America)