

Bachelorarbeit  
im Bachelorstudiengang  
Betriebswirtschaft  
an der Hochschule für angewandte Wissenschaften Neu-Ulm

**Künstliche Intelligenz und Prompt-Engineering am Beispiel der Marktforschung**

Erstkorrektor: Prof. Dr. Sascha Fabian

Zweitkorrektorin: Prof. Dr. Sonja Köppl

Verfasserin: Alina Alles (Matrikel-Nr.: 283185)

Thema erhalten: 02.01.2024

Arbeit abgegeben: 01.05.2024

## **Inhaltsverzeichnis**

I. Abkürzungsverzeichnis .....	IV
II. Glossar .....	VI
III. Abbildungsverzeichnis .....	XIV
IV. Abstract .....	XV
5. Einleitung .....	17
6. Theoretische Grundlagen .....	19
6.1 Künstliche Intelligenz und ChatGPT: Die Entwicklung von Sprachmodellen .....	19
6.2 Die Marktforschung .....	24
7. KI und ChatGPT in der Marktforschung.....	25
7.1 Potenziale von Künstlicher Intelligenz in der Marktforschung .....	25
7.2 Potenziale von ChatGPT in der Marktforschung .....	26
7.3 Grenzen von Sprachmodellen und ChatGPT .....	27
7.4 Datenschutz und Ethik .....	28
8. Prompt-Engineering in der Marktforschung .....	30
8.1 Definition des Prompt-Engineering .....	30
8.2 Relevanz von Prompt-Engineering .....	31
8.3 Methoden und Strategien des Prompt-Engineering .....	33
8.3.1 Optimierung von Prompts .....	33
8.3.2 Prompt-Engineering-Strategien.....	35
8.3.3 Large-Language-Model-Einstellungen .....	39
8.4 Prompt-Framework .....	39
8.5 Erforderliche Fähigkeiten für Prompt-Engineers .....	41
8.6 Kritik an Prompt-Engineering .....	42
9. Methodik .....	43
9.1 Experteninterviews .....	44
9.2 Prompthaton .....	45

10. Ergebnisse der Forschung .....	45
11. Diskussion der Ergebnisse.....	59
11.1 Diskussion der Hypothesen .....	59
11.2 Beantwortung der Forschungsfrage.....	63
11.3 Einordnung in den Forschungsstand und Limitationen.....	64
12. Fazit.....	65
13. Literaturverzeichnis.....	68
14. Übersicht verwendeter Hilfsmittel .....	78
XIV. Anhang.....	79

## **I. Abkürzungsverzeichnis**

0S: Zero-Shot-Prompting

1S: One-Shot-Prompting

AI: Artificial-Intelligence

API: Application-Programming-Interface

CoT: Chain-of-Thought-Prompting

DL: Deep-Learning

FM: Foundation-Model

FS: Few-Shot-Prompting

GenAI: Generative-AI

GPT: Generative-Pre-trained-Transformer

ITZ Plus Biberach: Innovations- und Technologietransferzentrum Plus Biberach GmbH

KI: Künstliche Intelligenz

KNN: Künstliches Neuronales Netzwerk

LLM: Large-Language-Model<sup>1</sup>

LM: Language-Modeling

Mafo: Marktforschung

ML: Machine-Learning

NLG: Natural-Language-Generation

NLP: Natural-Language-Processing

NLU: Natural-Language-Understanding

PE: Prompt-Engineering

PF: Prompt-Framework

PLM: Pre-trained-Language-Model

---

<sup>1</sup> Anmerkung: Der Begriff Sprachmodell wird in dieser Arbeit synonym zu LLM verwendet.

RP: Role-Prompting

SP: Shot-Prompting

TM: Transformer-Model

## II. Glossar

**Advanced-Data-Analytics:** Beschreibt eine Sammlung von Techniken der Datenanalyse, wie das ML, die von Unternehmen insbesondere für Vorhersagezwecke eingesetzt werden, um ihre Entscheidungsfindung zu verbessern (Coursera 2024).

**Agent:** Ein Computerprogramm, das Aktionen basierend auf getroffenen Entscheidungen ausführt, um zu einem bestimmten Ziel zu gelangen (Fabarius 2023, S. 295).

**AI-Act:** Ein Gesetz der Europäischen Union (EU), das damit die weltweit erste staatliche Regulierung von KI und den Rahmen für dessen Einsatz in Europa bildet (Hübner 2024).

**Application-Programming-Interface (API):** APIs sind ein Konzept der Softwareentwicklung, die als gemeinsame Sprache zwischen verschiedenen Softwarekomponenten dienen. APIs stellen eine Reihe an Regeln und Protokollen für die Kommunikation zur Verfügung, wodurch sie die Interaktion zwischen mehreren Anwendungen, Teilen der Hardware oder Datenbanken ermöglichen. Zudem sind APIs eine der elementaren Baueinheiten von Apps, die den Zugriff auf andere Apps, Datensätze oder Dienste, die üblicherweise von einer anderen Instanz entwickelt wurden, befähigen. APIs bieten Software- sowie Appentwicklern ein gewisses Maß an Standardisierung, insbesondere für die Anbindung an vernetzte Systeme und große Plattformen (Williams 2024). Im Kontext von KI fungieren sie als Brücke zwischen den intelligenten Maschinen und den jeweiligen Diensten, um den Zugriff zu gewährleisten und einen kontextbezogenen Dialog zu erlauben (Lamb 2023).

**Argumentationsfähigkeiten (Reasoning-Abilities):** Das „Reasoning“ beschreibt einen kognitiven Prozess, um zu Schlussfolgerungen zu gelangen, indem Logik, Argumente und Beweise verwendet werden und bildet einen grundlegenden Aspekt der menschlichen Intelligenz. Reasoning-Abilities kommen eine entscheidende Rolle bei Aktivitäten wie Entscheidungsfindung, Problemlösung und kritischem Denken zu. In jüngster Zeit haben Fortschritte im Bereich der natürlichen Sprache LLMs hervorgebracht, bei denen sich Argumentationsfähigkeiten beobachten lassen, wenn sie ausreichend groß sind (Huang/Chang 2023, S. 1).

**Artificial-Intelligence (AI):** Der Fokus wird auf die Ermöglichung von Computern, aus ihren Erfahrungen zu lernen, gesetzt, indem Daten mithilfe von fortschrittlichen Algorithmen verarbeitet werden. AI umfasst ein weites Feld, das Teilgebiete wie das ML, DL und NLP beinhaltet (Tauli 2019, S. 179).

**Assistant:** Ein KI-Modell, das den Nutzer bei seinen täglichen Tätigkeiten unterstützt (Taulli 2019, S. 184).

**Aufmerksamkeits- oder Selbstaufmerksamkeitsmechanismen (Attention- or Self-attention-Mechanisms):** Ermöglicht einem KI-Modell, die Beziehungen zwischen den Wörtern zu erfassen, unabhängig davon, wie weit die Wörter voneinander entfernt stehen. Dadurch wird bestimmt, welche Wörter und Sätze in einem Text als wichtig zu beachten sind (Toews 2023), was entscheidend für Aufgaben im Bereich des NLP ist, wie die Übersetzung und die Beantwortung von Fragen (Hadi u. a. 2023, S. 4).

**BERT:** Bidirectional-Encoder-Representations-from-Transformers (BERT) bezeichnet ein Sprachpräsentationsmodell (Language-Representation-Model), das entwickelt wurde, um tiefe bidirektionale Repräsentationen aus unbeschriftetem Text zu trainieren, indem rechte und linke Kontexte in allen Schichten gemeinsam konditioniert werden (Devlin u. a. 2019, S. 1).

**Best-Practice:** Beschreibt die bestmögliche und bereits erprobte Methode zur Durchführung eines Vorgangs (Duden o. J.).

**Big-Data:** Technologiekatgorie, dass die Verarbeitung von hohen Datenmengen umfasst (Taulli 2019, S. 179).

**Black-Box:** Stellt das bedeutsame Problem dar, dass mit Fortschritt der KI ein Mangel an Transparenz und Verantwortlichkeit in den Entscheidungsprozessen der KI aufgetreten ist (Mehta 2023). In der Regel werden Sprachmodelle sowie DL-Modelle als „Black-Box“ bezeichnet, da sich ihre Ergebnisse gelegentlich als nicht nachvollziehbar präsentieren (Frawan/Khasawneh 2023, S. 9).

**Chatbot:** Bezeichnet ein Programm, das auf die automatische Beantwortung von Nachrichten ausgelegt ist, die von Nutzern eingesendet werden und damit eine „konversationsähnliche Interaktion“ imitiert (Fabarius 2023, S. 296).

**Chat-Interface:** Beschreibt die Benutzeroberfläche eines Chatbots, die es Nutzern erlaubt, Nachrichten an diesen zu schicken und Antworten zu erhalten (Fabarius 2023, S. 296).

**Computerlinguistik (Computational-Linguistics):** Bezieht sich im weitesten Sinne auf den Einsatz von computergestützten Methoden zur Untersuchung von Sprachphänomenen (Luz 2022, S. 373).

**CPU (Central-Processing-Unit):** Komponente eines Computersystems, die grundlegende Operationen des Systems durchführt, die Daten mit dem Speicher austauscht und andere Komponenten des Systems verwaltet (Merriam-Webster 2024).

**Custom-GPT:** GPT-Modelle, die anhand von eigenen Daten feinabgestimmt werden können und somit eine auf die eigene Anwendung zugeschnittene Version des Modells darstellen (Lim/Wu/Miller 2021).

**Datenverarbeitungsvereinbarung (Data-Processing-Agreement):** Bezeichnet ein rechtsverbindliches Dokument, das den Umfang und den Zweck der Datenverarbeitung sowie die Beziehung zwischen dem für die Verarbeitung Verantwortlichen und dem Auftragsverarbeiter regelt (GDPR 2023).

**Deep-Learning (DL):** Ein Teilgebiet des ML, das künstlich neuronale Netzwerke mit vielen Schichten von Neuronen nutzt, um komplexe Probleme zu lösen (Klimczak/Petersen 2023, S. 43). Eine ausführliche Definition ist Anhang 3 zu entnehmen.

**Digitalisierungszentrums Ulm, Alb-Donau, Biberach, Neu-Ulm (DZ):** Bildet eine zentrale Anlaufstelle für kleine und mittlere Unternehmen in Baden-Württemberg, die Unterstützung bei der digitalen Transformation bietet (DZ 2024).

**DSGVO (Datenschutz-Grundverordnung):** Ein im Jahr 2018 eingeführtes Gesetz, das den Umgang von Unternehmen mit personenbezogenen Daten europaweit einheitlich regelt (Bundesministerium der Justiz 2023).

**Feinabstimmung (Fine-Tuning):** Transfer-Lernmethode, die darauf ausgerichtet ist, dass in vortrainierten neuronalen Netzen eingebettete Wissen zu nutzen, um es auf neue Anwendungsfälle anzuwenden. Im Kontext des NLP findet die Feinabstimmung ihren Einsatz in der Anpassung von vortrainierten Sprachmodellen, z. B. GPT-3.5. oder GPT-4, an spezifische Aufgaben wie die Sentiment-Analyse (Zheng u. a. 2023, S. 4; Junco 2023).

**Foundation-Model (FM):** Unter FMs sind im Wesentlichen jegliche KI-Modelle zu verstehen, die ein Training auf einer umfangreichen Datenbasis aufweisen und die Adaption an ein breites Spektrum an Aufgaben erlauben (Bommasani u. a. 2021, S. 3). Eine ausführliche Definition ist Anhang 4 zu entnehmen.



**Generative-AI (GenAI):** Generative KI-Systeme, die auf FMs basieren und sich im Wesentlichen durch ihre Fähigkeit auszeichnen, neuartige Inhalte aus Anweisungen oder Beispielen zu generieren (Dolata/Lange/Schwabe 2024, S. 2; Härlin u. a. 2023). Eine ausführliche Definition ist Anhang 5 zu entnehmen.

**Generative-Pre-trained-Transformer (GPT):** Bezeichnet ein KI-Modell, das auf die natürliche Sprachverarbeitung ausgerichtet ist und auf einer Transformer-Architektur basiert. Das Pre-Traning bzw. Vortraining erfolgt auf großen Textkorpora (Fabarius 2023, S. 299). Eine ausführliche Definition ist Anhang 7 zu entnehmen.

**GPU (Graphics-Processing-Unit):** Spezieller Prozessor, der zur schnellen Verarbeitung von rechenintensiven Anwendungen entwickelt wurde, wie die Verarbeitung von Grafiken (Fabarius 2023, S. 300).

**In-Context-Learning (In-Kontext-Lernen):** In-Kontext-Lernen verleiht LLMs, durch die Kombination aus Demonstrationsbeispielen und Aufgabenbeschreibung in Prompts, die Fähigkeit, neue Aufgaben zu bewältigen (Zhao u. a. 2023, S. 93).

**Innovations- und Technologietransferzentrum (ITZ) Plus Biberach GmbH:** Kompetenzzentrum, das „Raum für die produktive Entwicklung nachhaltiger Innovationen“ bietet (ITZ Plus 2023).

**Insights bzw. Consumer-Insights:** beschreiben Einsichten oder Erkenntnisse über die Einstellung, das Verhalten, die Präferenzen und Bedürfnisse sowie die Demografie von Kunden. Sie werden in der Marktforschung und im Marketing zur Optimierung von strategischen Entscheidungen und zur Gewinnung eines besseren Verständnisses über die Zielgruppe eingesetzt (Bünthe 2023, S. 21).

**Instruktionsabstimmung (Instruction-Tuning):** Bezieht sich auf den Prozess des weiteren Trainings von LLMs, was eine entscheidende Technik zur Verbesserung der Kontrollierbarkeit und der Fähigkeiten von LLMs bildet (Zhang u. a. 2024, S. 1).

**Kontext:** Beschreibt eine spezifische Umgebung oder Situation, in der eine Benutzeranfrage stattfindet. Diese muss der Chatbot bei seiner Ausgabe berücksichtigen (Fabarius 2023, S. 302).

**Korpora:** Als Korpora werden digitalisierte, maschinell lesbare Sprachdaten beschrieben (Sasaki/Witt 2004, S. 195).

**Künstliches Neuronales Netzwerk (KNN):** Stellt ein Netzwerk von künstlichen Neuronen dar, die unter Zusammenarbeit Informationen analysieren, um ein bestimmtes Ziel zu verwirklichen. Dieser Prozess weist Ähnlichkeiten zu dem menschlichen Gehirn auf und wird zur Mustererkennung und Prognose angewendet wird (Fabarius 2023, S. 302, 304).

**Large-Action-Model (LAM):** LAM ist eine Anlehnung an den Begriff „Large-Language-Model“ (LLM). Anders als LLMs, die Anweisungen in natürlicher Sprache als Eingaben annehmen und Ausgaben auf Grundlage von Wahrscheinlichkeiten generieren, gehen LAMs einen Schritt weiter, indem sie Aktionen daraus ableiten und diese ausführen. In diesem Kontext werden sie ebenfalls als Agenten bezeichnet, da sie selbständig Aufgaben ausführen (Jöckel 2024).

**Lemmatisierung (Lemmatization):** Ein Prozess im Bereich des NLP, dass sich auf die Ermittlung von ähnlichen Stammwörtern spezialisiert und die Entfernung von Präfixen und Affixen enthält (Tauli 2019, S. 109).

**Machine-Learning (ML):** Ein Teilbereich der KI, das Modelle und Algorithmen nutzt, um von Daten zu lernen und Prognosen zu treffen (Fabarius 2023, S. 303). Eine ausführliche Definition ist Anhang 2 zu entnehmen.

**Named-Entity-Recognition:** Ein Verfahren im NLP-Prozess, das die Identifizierung von Wörtern, die Personen, Organisationen und Orte repräsentieren, umfasst (Tauli 2019, S. 182).

**Natural-Language-Generation (NLG):** Ein Teilbereich des NLP, das im Allgemeinen die maschinelle, automatische Erstellung von natürlicher Sprache bezeichnet (Wagener 2023, S. 90; Kavlakoglu 2020).

**Natural-Language-Understanding (NLU):** Ein Teilbereich des NLP, das die semantische und syntaktische Analyse von Sprache und Text verwendet, um die Satzbedeutung zu bestimmen (Kavlakoglu 2020).

**Neuronale Netze:** Bezeichnet einen Ansatz im Feld der KI, der sich an biologischen neuronalen Netzwerken im menschlichen Gehirn ausrichtet und als einer der leistungsstärksten Algorithmen für ML gilt (Fabarius 2023, S. 304; Maslej-Krešňáková u. a. 2020, S. 10).

**Neuronen:** Neuronen stellen die Grundbestandteile in einem Künstlich Neuronales Netzwerk (KNN) dar, die Eingaben erhalten und verarbeiten, um anschließend eine Ausgabe zu erzeugen (Fabarius 2023, S. 304).

**OpenAI:** Ein Forschungsunternehmen, mit Sitz in San Francisco, das seinen Fokus auf die Entwicklung von KI setzt und im Dezember 2015 gegründet wurde (Fitria 2023, S. 45). Das Unternehmen etablierte sich zu einem der führenden Akteure in der Landschaft der KI-Forschung (Mhlanga 2023, S. 6). Zu den bekanntesten Produkten von OpenAI zählen die GPT-Serie, darunter ChatGPT (Fitria 2023, S. 45). Eine ausführliche Definition ist Anhang 9 zu entnehmen.

**Pre-trained-Language-Models (PLM):** Beschreiben Sprachmodelle, die auf TMs basieren. Diese sind mithilfe von großen Korpora vortrainiert und weisen eine hohe Leistungsfähigkeit bei der Lösung verschiedener NLP-Aufgaben auf (Zhao u. a. 2023, S. 1). PLMs bedienen sich neuronaler Netze, um eine Vektordarstellung von Wörtern zu lernen, die den Kontext berücksichtigt, in dem das Wort erscheint (Hadi u. a. 2023, S. 1). PLMs erzielten beachtliche Erfolge im Bereich des NLP, die zu einem Paradigmenwechsel vom überwachten Lernen zum Vortraining mit abschließender Feinabstimmung führten (Wang u. a. 2023, S. 51).

**Prompt:** Bezeichnet eine Eingabeaufforderung in natürlicher Sprache an ein LLM. Ein Prompt enthält eine Reihe an Anweisungen, die das LLM programmieren, indem sie das Modell anpassen oder seine Fähigkeiten verbessern (White u. a. 2023b, S. 1).

**Prompting:** Bezeichnet das Eingeben von Prompts, womit das Prompting eine entscheidende menschliche Fähigkeit darstellt, die als „Schnittstelle zwischen Mensch und Modell“ fungiert (Steinmann/Piazza 2024, S. 405). Das Prompting hat sich, auf Grundlage der natürlich sprachlichen Schnittstelle zwischen KI und Mensch, zu einem signifikanten Ansatz für die Nutzung von LLMs zur Lösung verschiedener Aufgaben entwickelt (Zhao u. a. 2023, S. 83).

**Prompt-Template:** Ein Prompt-Template bildet einen Rahmen, der Richtlinien für die Formulierung von Prompts bietet, um sie effektiv und strukturiert zu gestalten (Youngblood 2023).

**Regressionsanalyse:** Bezeichnet ein statistisches Verfahren, die zur Untersuchung der Beziehung zwischen unabhängigen und abhängigen Merkmalen dient. Sie gibt eine mathematische Regressionsfunktion aus, die für die Erstellung von Prognosen und Zusammenhängen nützlich ist (Stoetzer 2020, S. 2).

**Reinforcement-Learning (Verstärkendes Lernen):** Bezeichnet ein Verfahren des Machine-Learning (ML). Hierbei wird ein Agent (Algorithmus) durch Bestrafungen oder Belohnungen trainiert, wie er in einer bestimmten Umgebung agieren soll (Fabarius 2023, S. 306; Bauer/Warschat 2021, S. 85).

**Reinforcement-Learning-from-Human-Feedback (RLHF):** RLHF nutzt die Algorithmen des Reinforcement-Learning, um LLMs durch das Lernen eines Belohnungsmodells an menschliches Feedback abzustimmen. Dieser Ansatz integriert den Menschen in die Trainingsschleife zur Entwicklung gut abgestimmter LLMs (Zhao u. a. 2023, S. 39).

**Sentiment-Analyse:** Stellt eine Methode der Textanalyse dar mit dem Ziel, Meinungen oder Stimmungen in einem Text zu identifizieren und zu beurteilen (Fabarius 2023, S. 307).

**Singularität:** Beschreibt den Zeitpunkt, an dem die KI den Menschen hinsichtlich seiner kognitiven Fähigkeit ebenbürtig ist (Wagener 2023, S. 20).

**Standard-Prompting:** Das Standard-Prompting nutzt Eingabe-Ausgabe-Paare als Beispiele, die als Fragen und Antworten formatiert sind. Es eignet sich für unkomplizierte Aufgaben, da es nur begrenzt dazu fähig ist, mehrstufige Argumentationsaufgaben erfolgreich zu lösen (Badhan o. J.).

**Stemming:** Beschreibt den Prozess zur Reduzierung eines Wortes auf seinen Wortstamm, das über die Entfernung von Suffixen und Affixen geschieht (Taulli 2019, S. 108).

**Supervised-Fine-Tuning (Überwachte Feinabstimmung):** Beschreibt ein Verfahren, bei dem ein vortrainiertes Sprachmodell, unter Verwendung von markierten Daten, an eine bestimmte Aufgabe angepasst wird (Martinez 2023).

**Supervised-Learning (Überwachtes Lernen):** Ist eine Ausprägung des Machine-Learning (ML), bei der ein KI-Modell auf Grundlage von beschrifteten Trainingsdaten lernt, Vorhersagen auf unbekanntem Daten zu treffen (Fabarius 2023, S. 308).

**Texteinbettung (Text-Embedding):** Texteinbettungen bezeichnen Vektoren, die die Verwandtschaft von Textzeichenketten messen (OpenAI o. J.e).

**Token:** Tokens beschreiben die kleinsten Einheiten, die in einem Textstück für LLMs eine Bedeutung aufweisen. Tokens bestehen u.a. aus Wörtern, Unterwörtern und Zeichen. Mithilfe von Tokens sind LLMs in der Lage, Texteingaben in variabler Länge aufzunehmen und in standardisierte sowie leicht zu verarbeitende Segmente zu konvertieren (AISchool 2023).

**Tokenisierung (Tokenization):** Ein Verfahren im NLP-Prozess, bei dem der Rohtext analysiert und in Sequenzen von einzelnen Tokens segmentiert wird, die anschließend als Eingabe für LLMs verwendet werden (Zhao u. a. 2023, S. 19; Taulli 2019, S. 106).

**Trainingsdaten:** Daten, die für die Entwicklung von KI-Algorithmen genutzt werden (Taulli 2019, S. 184).

**Transformer-Model (TM):** Ein TM bildet ein Künstlich Neuronales Netz (KNN), das Beziehungen zwischen Datenelementen in einer Sequenz identifiziert, indem es Aufmerksamkeits- oder Selbstaufmerksamkeitsmechanismen (Attention- or Self-attention-Mechanisms) einsetzt (Toews 2023; Merritt 2022). Eine ausführliche Definition ist Anhang 5 zu entnehmen.

**Turing-Test:** Bezeichnet einen Test, der von Alan Turing entwickelt wurde und zur Feststellung dient, ob ein System den Status einer echten KI erreicht hat. Der Test beinhaltet eine Person, die Fragen an zwei Teilnehmer stellt, die aus einem Menschen und einem Computer bestehen. Falls nicht unterschieden werden kann, wer der menschliche Teilnehmer ist, besteht der Computer den Turing-Test (Taulli 2019, S. 184).

**Unsupervised-Learning (Unüberwachtes Lernen):** Bezeichnet ein Verfahren des Machine-Learning (ML), bei dem das KI-Modell aus unbeaufsichtigten Daten lernt, ohne dass die Ausgaben oder Ziele im Vorfeld bekannt sind (Fabarius 2023, S. 309).

**Unsupervised-Pre-Training (Unüberwachtes Vortraining):** Eine Technik des maschinellen Lernens (ML), die ermöglicht, das Wissen in großen Mengen an unstrukturierten Textdaten zu nutzen. Dies geschieht, indem die unmarkierten Daten verwendet werden, um ein vorläufiges Modell zu trainieren, das im Anschluss mit einer geringeren Menge an markierten Daten feinabgestimmt wird (Saturn Cloud 2023; Yang u. a. 2021, S. 1).

**Use-Case:** Bezeichnet eine strukturierte Beschreibung eines spezifischen Anwendungsfalls (Küpeli 2024).

### III. Abbildungsverzeichnis

Abbildung 1: Überblick über die Teilgebiete der KI, die zur Entwicklung von Sprachmodellen wie ChatGPT beigetragen haben.....	19
Abbildung 2: Entwicklung der GPT-Serie .....	24
Abbildung 3: Elemente eines Prompts .....	31
Abbildung 4: Gegenüberstellung von Zero-, One- und Few-Shot-Prompting am Beispiel einer Übersetzungsaufgabe .....	37
Abbildung 5: Gegenüberstellung von Standard-Prompting und Chain-of-Thought-Prompting im Few-Shot-Prompting .....	38
Abbildung 6: Übersicht über Large-Language-Model-Einstellungen.....	39
Abbildung 7: Beispiel für einen Prompt nach dem RISE-Framework.....	40
Abbildung 8: Rahmenkonzept für die strukturierte und zielgerichtete Entwicklung eines Prompts.....	61
Abbildung 9: Konzeption für eine interne Schulung in Marktforschungsunternehmen .....	63

## IV. Abstract

Fortschritte im Bereich der natürlichen Sprachverarbeitung führten zur Entwicklung von Sprachmodellen wie ChatGPT, die die Interaktion mit ihnen in natürlicher Sprache erlauben. Im Zuge dessen ist das Prompt-Engineering (PE) als eine Disziplin entstanden, die sich der effizienten Bedienung von Sprachmodellen widmet, indem sie sich mit der systematischen Optimierung von Prompts, Eingaben in natürlicher Sprache, befasst. Mit dem Hintergrund der zunehmenden Integration von Sprachmodellen in den Marktforschungsprozess, besteht das Ziel der vorliegenden Arbeit, zu untersuchen, ob Marktforscher das PE als eine weitere Kompetenz erlernen sollten, um KI-Modelle zielgerichtet zu bedienen und die gewünschten Ergebnisse zu erreichen. Das Forschungsziel spiegelt sich in der Forschungsfrage: *„Steht die Marktforschung durch den Einsatz von Sprachmodellen, insbesondere ChatGPT, in der Verantwortung, Prompt-Engineering als eine neue Kompetenz zu erlernen?“* wider. Zur Beantwortung dieser Frage wurden im Rahmen einer empirischen Untersuchung Experteninterviews geführt und die Veranstaltung „Prompthaton“ besucht, um einen umfassenden Einblick in die Thematik zu gewinnen. Die resultierenden Erkenntnisse verdeutlichen, dass PE eine maßgebliche Rolle bei der Zusammenarbeit mit Sprachmodellen in der Marktforschung spielt, indem es die Relevanz und Zuverlässigkeit KI-generierter Ergebnisse gewährleistet. Die Experten erachten es mithin als erstrebenswert, PE als eine weitere Kompetenz in der Marktforschung zu etablieren. Hierbei ist anzunehmen, dass das PE sich als ein breites Spektrum von Kompetenzstufen in der Marktforschung abbilden wird. Da das PE eine junge Fachdisziplin darstellt, ist eine weiterführende Forschung ratsam, die die wachsende Etablierung des PE in der Marktforschung verfolgt.

Advances in the field of Natural-Language-Processing have led to the development of language models such as ChatGPT that allow interaction with them in natural language. In the course of this, prompt engineering (PE) has emerged as a discipline dedicated to the efficient operation of language models by dealing with the systematic optimisation of prompts, inputs in natural language. Against the background of the increasing integration of language models into the market research process, the aim of this thesis is to investigate whether market researchers should learn PE as a further competence in order to operate AI models in a targeted manner and achieve the desired results. The research objective is reflected in the research question: *"Does the use of language models, in particular ChatGPT, mean that market researchers have a responsibility to learn prompt engineering as a new competence?"*. To answer this question, expert interviews were conducted as part of an empirical study and the "Prompthaton" event was attended in order to gain a comprehensive insight into the topic. The resulting findings make it clear that PE plays a key role in working with language models in market research by ensuring the relevance and reliability of AI-generated results. The experts therefore consider it desirable to establish PE as a further competence in market research. In this context, it can be assumed that PE will be reflected as a broad spectrum of competence levels in market research. As PE is a young specialised discipline, further research is advisable to pursue the growing establishment of PE in market research.



## 5. Einleitung

### Problemstellung und Relevanz

In den vergangenen Jahren erfuhr der KI-Bereich eine Revolution durch die Entwicklung von Sprachmodellen wie ChatGPT. Diese KI-Modelle ermöglichen das Programmieren in natürlicher Sprache, wodurch sie die Zugänglichkeit zu fortschrittlichen KI-Technologien erweitern (Kumar 2011, S. 2, 7). Parallel etablierte sich das Prompt-Engineering (PE) als eine zunehmend bedeutsame Fähigkeit, die auf die effiziente Kommunikation mit Sprachmodellen abzielt (A.Shaji George/A. S.Hovan George 2023, S. 2–3; White u. a. 2023a, S. 1). Diese Entwicklungen wirken sich ebenfalls auf die Marktforschung (Mafo) aus (Jain u. a. 2023, S. 3). Die KI weist das Potenzial auf, insbesondere die Mafo nachhaltig zu transformieren, die, wie kaum eine andere Fachdisziplin, ihr Methoden- und Kompetenzspektrum aufgrund des technologischen Fortschritts fortwährend anpasste (Hoxtell 2020, S. 3). Unternehmen im Bereich der Mafo sind zunehmend bestrebt, Sprachmodelle in ihre Forschungspraxis zu integrieren (Drăghici u. a. 2023, S. 43; Mallikarjunaradhya/Pothukuchi 2021, S. 445). Infolgedessen gewinnt die Notwendigkeit einer produktiven Interaktion mit Sprachmodellen zunehmend an Relevanz (Steinmann/Piazza 2024, S. 402). Vor diesem Hintergrund ist zu untersuchen, ob das PE in der Mafo an Bedeutung zunehmen und deren Kompetenzspektrum erweitern wird.

### Stand der Forschung

Die wachsende Einbindung von KI, insbesondere die Nutzung innovativer Sprachmodelle wie ChatGPT, verspricht eine transformative Veränderung der Mafo (Drăghici u. a. 2023, S. 41; Jain u. a. 2023, S. 3). In den betroffenen Unternehmen besteht ein dringender Bedarf an Expertise zur Optimierung der Zusammenarbeit zwischen Menschen und KI-Modellen, die das PE bereitstellt (A.Shaji George/A. S.Hovan George 2023, S. 3). Allerdings wird deutlich, dass die Thematik des PE in der Mafo geringfügig erkundet ist, während bereits zahlreiche wissenschaftliche Artikel im Bereich des Marketings bestehen (Steinmann/Piazza 2024; A.Shaji George/A. S.Hovan George 2023, S. 5; Fraiwan/Khasawneh 2023). Es ist anzunehmen, dass Fähigkeiten im PE von entscheidender Bedeutung für die Bedienung von Sprachmodellen in der Mafo sind und mithin als eine relevante Kompetenz anzustreben sind. Somit hat dieses Forschungsdefizit unmittelbare Auswirkungen auf die Marktforschungspraxis. Dessen Untersuchung führt nicht nur zu relevanteren Ergebnissen, sondern fördert zudem die Akzeptanz und Implementierung von KI-Modellen in der Mafo.

## **Ziel der Arbeit und Forschungsfrage**

Die vorliegende Bachelorarbeit widmet sich der Frage, ob durch Sprachmodelle wie ChatGPT eine neue Dimension in der Mafo eröffnet wird, indem PE als eine neuartige Kompetenz in der Handhabung mit Sprachmodellen gefragt ist. Dementsprechend wird untersucht, ob im Rahmen der Mafo eine wachsende Notwendigkeit besteht, Fähigkeiten im PE zu erwerben, um effektiv mit Sprachmodellen zu interagieren. Das Forschungsziel wird mithilfe der Forschungsfrage: „*Steht die Marktforschung durch den Einsatz von Sprachmodellen, insbesondere ChatGPT, in der Verantwortung, Prompt-Engineering als eine neue Kompetenz zu erlernen?*“ erarbeitet.

## **Abgrenzung des Themas**

Die Bachelorarbeit thematisiert die Mafo als ein Anwendungsgebiet des PE. Die Untersuchung bezieht sich auf die Frage, ob PE, angesichts der zunehmenden Bedeutsamkeit und Implementierung von KI und Sprachmodellen, als weitere Kompetenz in der Mafo anzustreben ist. Hierbei dient ChatGPT als Betrachtungsgegenstand für den Einsatz von Sprachmodellen innerhalb der Mafo. Aufgrund des begrenzten Umfangs sowie fortschreitender Forschungsarbeiten im Bereich des PE (Chen u. a. 2023, S. 2), erhebt die Bachelorarbeit keinen Anspruch auf eine vollständige Betrachtung der Vielzahl an PE-Methoden, weswegen sie eine Momentaufnahme dieses dynamischen Gebiets darstellt.

## **Gang der Arbeit**

Zu Beginn dieser Bachelorarbeit erfolgen in Kapitel I bis IV Übersichten über Informationen, die zu einem holistischen Verständnis dieser Arbeit beitragen. Das fünfte Kapitel widmet sich dem einleitenden Teil, das die Problemrelevanz und die Zielsetzung der Arbeit mithilfe der Forschungsfrage erläutert. Das sechste Kapitel dient zur Vermittlung eines tiefgreifenden Verständnisses von KI, Sprachmodellen, ChatGPT und der Mafo, um eine theoretische Grundlage für die nachfolgenden Kapitel zu legen. Daraufhin beleuchtet Kapitel 7 das Potenzial, das die Nutzung von KI und insbesondere ChatGPT für die Mafo bietet sowie mögliche Grenzen der Sprachmodelle. Sodann werden im achten Kapitel das PE, dessen Methoden und erforderliche Fähigkeiten erläutert sowie mögliche Kritikpunkte am PE berücksichtigt. Kapitel 9 umfasst die methodologische Herangehensweise der im Rahmen dieser Arbeit durchgeführten empirischen Forschung. Das zehnte Kapitel stellt die resultierenden Ergebnisse der Forschung dar. Im Anschluss daran werden in Kapitel 11 die Ergebnisse diskutiert und mögliche Limitationen der Arbeit betrachtet. Die Arbeit endet mit einem abschließenden Fazit in Kapitel 12.

## 6. Theoretische Grundlagen

Im folgenden Kapitel wird ein Verständnis für das Gebiet der natürlichen Sprachverarbeitung und die daraus resultierenden Sprachmodelle, im Spezifischen ChatGPT, konstituiert und das Fachgebiet der Marktforschung (Mafo) erläutert.

### 6.1 Künstliche Intelligenz und ChatGPT: Die Entwicklung von Sprachmodellen

Das Ziel in diesem Unterkapitel besteht darin, ein allgemeines Verständnis der KI zu etablieren und einen Einblick in die grundlegenden Konzepte der natürlichen Sprachverarbeitung als Teilgebiet der KI zu eröffnen. Zudem wird ChatGPT als Betrachtungsgegenstand für ein innovatives Sprachmodell beleuchtet.

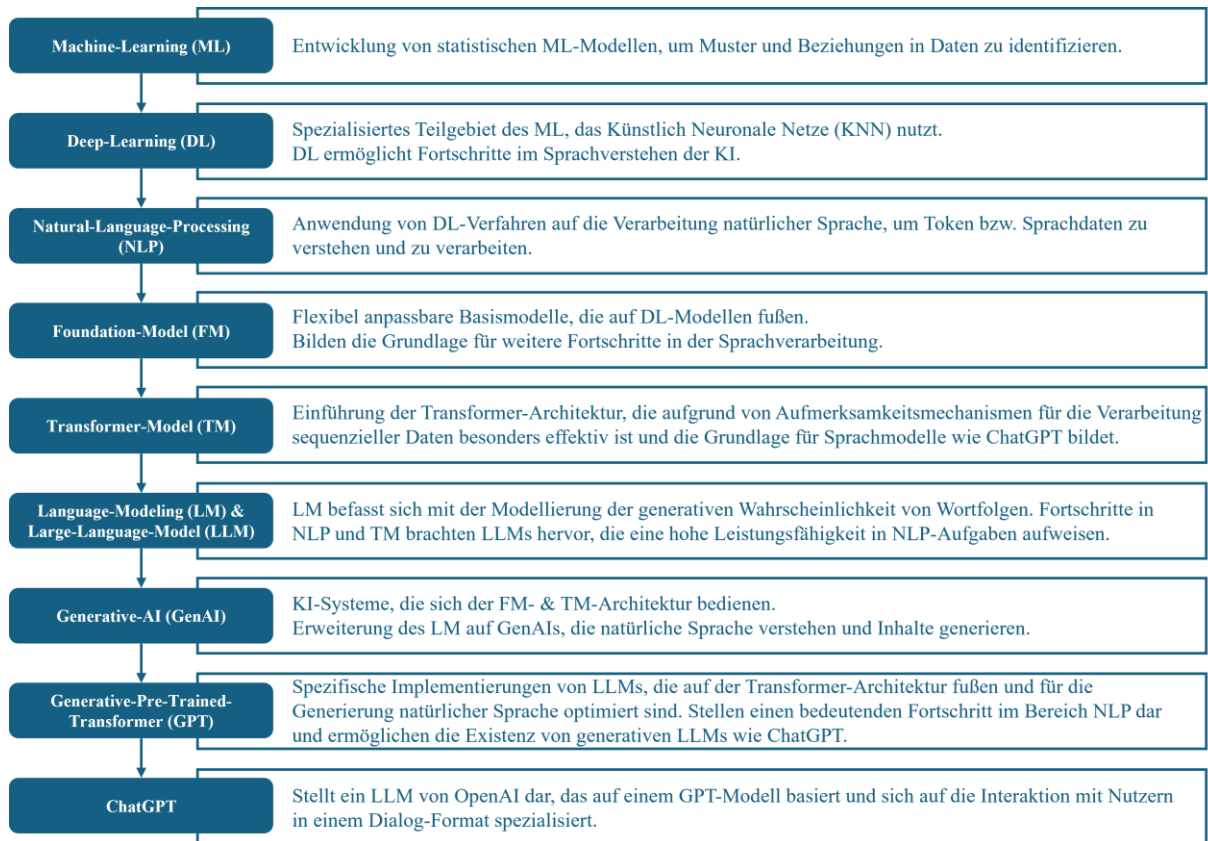


Abbildung 1: Überblick über die Teilgebiete der KI, die zur Entwicklung von Sprachmodellen wie ChatGPT beigetragen haben

Quelle: nach eigener Darstellung in Anlehnung an Dolata/Lange/Schwabe 2024, S. 2; Kashyap 2024, S. 6; Manghani 2024; Hadi u. a. 2023, S. 4, 10; Klimczak/Petersen 2023, S. 43; Toews 2023; Yenduri u. a. 2023, S. 2; Zhao u. a. 2023, S. 1, 3; Bommasani u. a. 2021, S. 3; Kavlakoglu 2020; Hecker u. a. 2017, S. 8; Amazon Web Services, Inc. o. J.; IBM o. J.b

Abbildung 1 bietet eine Darstellung der KI-Teilgebiete, die die Fortschritte in der Sprachverarbeitung sowie die Entwicklung von Sprachmodellen wie ChatGPT ermöglichten. Zur Vertiefung dieses Themenkomplexes finden sich Erläuterungen der Bereiche Machine-Learning (ML), Deep-Learning (DL), Foundation-Models (FMs), Transformer-Models (TMs), Generative-AI (GenAI), Generative-Pre-trained-Transformers (GPTs) sowie eine allgemeine Differenzierung von KI-Systemen in schwache und starke KI in den Anhängen 1 bis 7.

### **Künstliche Intelligenz im Allgemeinen**

Obwohl die Diskussion um KI wie ein aktuelles Trendthema erscheint, ist der Bereich der KI keineswegs neu: Bereits in den 1960er Jahren wurde die Definition und Verwendung der klugen Algorithmen diskutiert (Gentsch 2018, S. 16). Der ursprüngliche Begriff „Artificial-Intelligence“ (AI) wurde erstmalig durch John McCarthy im Jahr 1955 eingeführt. Dieser definierte KI als die Wissenschaft und Technik, intelligente Maschinen zu entwickeln (Jain u. a. 2023, S. 1). Bis zum gegenwärtigen Zeitpunkt besteht keine einheitliche Definition des KI-Begriffs. Vielmehr existieren zahlreiche Definitionsversuche, die je nach historischem oder fachlichem Hintergrund einen anderen Schwerpunkt setzen. Um den Begriff der KI zu verstehen, muss „Intelligenz“ definiert werden. Allerdings findet sich hierfür ebenfalls keine eindeutige Begriffserklärung, da Intelligenz in unterschiedlichen Dimensionen vertreten ist. In vielen Fällen lässt sich jedoch eine Kernaussage erkennen. Intelligenz wird grundlegend als die „Fähigkeit [des Menschen], abstrakt und vernünftig zu denken und daraus zweckvolles Handeln abzuleiten“ (Duden 2016 zitiert in Gentsch 2018, S. 17) verstanden. Intelligenz wird somit traditionell als eine vornehmlich menschliche Eigenschaft erachtet. In diesem Sinne soll KI das menschliche Verhalten nachahmen und menschlich agieren, ohne selbst menschlich zu sein (Gentsch 2018, S. 17–18). Da keine einheitliche Definition von KI existiert, wird für den Verlauf dieser Arbeit die vielfach zitierte Definition von Elaine Rich verwendet: „*Artificial Intelligence is the study of how to make computers do things at which, at the moment, people are better.*“ (Rich zitiert in Gentsch 2018, S. 18)

### **Natural-Language-Processing**

Sprache ist eine komplexe Fähigkeit des Menschen, die sich von der frühen Kindheit an entwickelt (Zhao u. a. 2023, S. 1). Konträr dazu besitzen Maschinen nicht auf natürliche Weise ein Verständnis für die menschliche Sprache, weshalb die Entwicklung künstlich intelligenter Algorithmen, die vergleichbar mit Menschen, Sprache verstehen und anwenden, eine Herausforderung darstellt (Gentsch 2018, S. 31). Die Implementierung reiner Wörterbücher ist für

Maschinen zwar problemlos zu bewältigen. Allerdings liegt der Sinngehalt der Kommunikation im Regelfall in der Semantik, d. h. „den Interpretationsregeln des Gesagten“ (Gentsch 2018, S. 31). Die Semantik der natürlichen Sprache, ist nicht einheitlich, sondern u. a. gebunden an die kulturelle Prägung, Grammatik und Intention des Gesagten, wodurch sie sich nicht unmittelbar für Maschinen systematisieren lässt (Gentsch 2018, S. 31). Natural-Language-Processing (NLP), auf Deutsch „Natürliche Sprachverarbeitung“, widmet sich der dargestellten Problematik und verzeichnete in den vergangenen Jahren die größten Durchbrüche im Bereich der KI (Esposito u. a. 2021, S. 1). Als eine Teildisziplin der KI, vereint NLP die Computerlinguistik (Computational-Linguistics) mit DL-Modellen und Verfahren des ML (Kumar 2011, S. 1; IBM o. J.b). Das NLP beinhaltet im Wesentlichen das „Verarbeiten, Verstehen und Generieren von Sprachen“ (Gentsch 2018, S. 31). Wird ein KI-Modell mit einer massiven Menge an Daten trainiert, ist es im Stande, Wortbedeutungen mit einer erhöhten Wahrscheinlichkeit zu erfassen (Gentsch 2018, S. 32), inklusive der Gefühle und Absichten des Geschriebenen oder des Gesagten (IBM o. J.b). Dies geschieht durch einen Prozess, der als Named-Entity-Recognition bekannt ist und die Identifikation benannter Entitäten und Wortmuster bezeichnet. Hierbei werden die Stammformen von Wörtern mithilfe von Methoden wie Tokenisierung (Tokenization), Lemmatisierung (Lemmatization) und Stemming analysiert (Kavlakoglu 2020). Die Sprachverarbeitung zählt zu den bedeutendsten Funktionen und Indikatoren von KI, denn ihre Autonomie beweist sich darin, ob sie menschliche Anweisungen verstehen sowie eigenständig realisieren. Mit NLP wird die natürliche Sprache als Standard für die Informationsübermittlung etabliert und bildet einen gemeinsamen „kommunikativen Nenner“ (Wagener 2023, S. 36) zwischen Menschen und Maschine, was im Gegensatz zu bisher angewandten, formalisierten Programmiersprachen wie Python oder Java steht (Gentsch 2018, S. 31). Die Ermächtigung von KI-Systemen, natürliche Sprache zu verstehen, erleichtert die Kommunikation mit ihnen um ein Vielfaches (Kumar 2011, S. 2). Hierdurch wird es sämtlichen Nutzern ermöglicht, mit NLP-Systemen zu interagieren, ohne Kenntnisse in Programmiersprachen zu benötigen (Kumar 2011, S. 7). Anwendungsfälle von NLP finden sich z. B. in der Sprachübersetzung, dem Beantworten von Fragen sowie im Rahmen der Sentiment-Analyse (Kavlakoglu 2020). Das NLP wird durch seine Teilgebiete Natural-Language-Understanding (NLU) und Natural-Language-Generation (NLG) ergänzt. Während sich Ersteres mit dem maschinellen Leseverständnis für die Erfassung des Sinngehalts, unter Beachtung von Kontext und Grammatik, befasst, beinhaltet Letzteres die auf einer Datenzufuhr basierende Generierung von Texten (Kavlakoglu 2020).

## Language-Modeling und Large-Language-Models

Seit der Entwicklung des Turing-Tests in den 1950er Jahren, einem Verfahren, das darauf abzielt, zu bestimmen, ob eine Maschine menschenähnliche Intelligenz besitzt, beschäftigten sich Forschende mit der Sprachintelligenz von Maschinen. In den letzten 20 Jahren profilierte sich insbesondere das Language-Modeling (LM) bzw. die Sprachmodellierung als ein prominenter Ansatz für die Förderung der sprachlichen Intelligenz von Maschinen. Als ein Teilgebiet des NLP, strebt das LM nach einer Modellierung der generativen Wahrscheinlichkeit von Wortfolgen, um das Auftreten zukünftiger oder fehlender Tokens zu prognostizieren (Pulyaev 2024; Zhao u. a. 2023, S. 1; Wang u. a. 2023, S. 1). Language-Models, d. h. künstlich intelligente Sprachmodelle, sind die Produkte dieser Anstrengungen, deren Entwicklung von statistischen, über neuronalen zu derzeitig vortrainierten Sprachmodellen bzw. Pre-trained-Language-Models (PLM) überging. Large-Language-Models (LLMs) stellen insofern die jüngste Entwicklung dar (Hadi u. a. 2023, S. 1). Fortschritte im Bereich des NLP brachten Foundation-Models (FMs) und Transformer-Models (TMs) hervor, die natürlichen Text als Eingabe akzeptieren und somit die LLMs bilden (Dolata/Lange/Schwabe 2024, S. 2; Zhao u. a. 2023, S. 4). Der Zusatz „Large“ gründet in einer erleichterten Unterscheidung der Language-Models in verschiedene Parameterskalen, wobei die Bezeichnung LLM für PLM mit herausragender Größe, d. h. mit einer Parameteranzahl im Milliardenbereich, verwendet wird (Zhao u. a. 2023, S. 1). Hierzu zählen u. a. die GPT-3- und GPT-4-Modelle von OpenAI (Hadi u. a. 2023, S. 1). Mit einer Skalierung des Modells wird eine erhöhte Modellkapazität erreicht, weshalb der Skalierungseffekt fortgehend ausgereizt wird, indem die Parameterskalen erhöht werden. Überschreitet die Parameterskala ein gewisses Niveau, weisen die erweiterten LLMs, neben einer deutlichen Leistungsoptimierung, weitere besondere Fähigkeiten auf (z. B. In-Context-Learning), die in kleinen Sprachmodellen wie BERT nicht zu finden sind. Die Interaktion mit einem LLM erfordert in der Regel die Eingabe von Prompts, d.h. Anweisungen in natürlicher Sprache. Diese stellen in einer Chat-basierten Umgebung eine Chat-Nachricht dar, die der Benutzer an LLMs wie ChatGPT sendet (White u. a. 2023b, S. 1). In der Vergangenheit wurde die Forschung zu LLMs weitgehend von der Wissenschaft und der Industrie vorangetrieben, wobei die Einführung von ChatGPT einen bedeutenden Fortschritt markiert und gesellschaftlich eine hohe Aufmerksamkeit erregte (Zhao u. a. 2023, S. 1).

## ChatGPT

ChatGPT (Chat-Generative-Pre-trained-Transformer) manifestiert sich als Produkt der Fortschritte im Bereich der natürlichen Sprachverarbeitung (Koubaa u. a. 2023, S. 1). Von OpenAI (siehe Anhang 9) entwickelt, ist es ein öffentlich zugängliches NLP-System (Jain u. a. 2023, S. 2), das menschenähnliche Konversationen generiert (Deng/Lin 2023, S. 81–82). ChatGPT weist das Potenzial auf, die Interaktion von Menschen mit Maschinen zu revolutionieren (Koubaa u. a. 2023, S. 11), indem es eine „beispiellose Kompetenz beim Verstehen und Generieren von Sprache“ (Koubaa u. a. 2023, S. 3) demonstriert. Aufgrund seiner Fähigkeit, mit Menschen in natürlicher Sprache zu kommunizieren, bedingt ChatGPT, seit seiner Veröffentlichung am 30. November 2022, maßgeblich die Diskussion um KI (Hadi u. a. 2023, S. 7; OpenAI 2022). Anfänglich basierte ChatGPT auf einem feinabgestimmten Modell der GPT-3.5-Serie und wurde entwickelt, um natürliche Sprache, d. h. sequenzielle Eingabedaten, ohne das Erfordernis einer Kennzeichnung zu verarbeiten (OpenAI 2022). Das GPT-Modell bildet hierbei ein „autoregressives Sprachmodell“ (Paass/Giesselbach 2023, S. 51), das den nächsten Token vorhersagt und sich auf bereits generierte beschränkt, um Prompts in natürlicher Sprache zu analysieren und die wahrscheinlichste Antwort zu bestimmen. Zudem wurde das Modell durch eine Kombination aus verstärktem (Reinforcement-Learning) und überwachtem Lernen (Supervised-Learning) auf Grundlage vergangener Konversationen sowie durch menschliches Feedback zur Feinabstimmung des Modells und seiner Ausgaben weiter optimiert (Sudmann u. a. 2023, S. 275; OpenAI 2022). Der Trainingsdatensatz basiert auf zahlreichen Internettexten. Jedoch sind dem Modell explizit keine spezifischen Quellen oder Texte bekannt, weshalb eine Verallgemeinerung statt einer Spezialisierung gewährleistet wird (Mittal 2023). Somit ist ChatGPT vielseitig einsetzbar (Sudmann u. a. 2023, S. 276). Mit GPT-4, der aktualisierten Version, besitzt die KI nach Schätzungen 1,76 Billionen Parameter (Bastian 2023), wodurch sie zu den größten Sprachmodellen zählt (IBM o. J.a). Abbildung 2 veranschaulicht eine vereinfachte Darstellung der Entwicklung der GPT-Serie von OpenAI, bis zum zuletzt veröffentlichten GPT-4-Turbo-Modell. Diese Modelle unterscheiden sich in ihrer Größe, indem jede weitere Version eine Hochskalierung der Trainingsdaten und Parameter erfuh (Alawida u. a. 2023, S. 3). Zudem ist Anhang 8 ChatGPTs eigene Antwort darauf, wie sich das LLM selbst beschreibt sowie eine detaillierte Betrachtung seiner Entwicklung zu entnehmen.




Abbildung 2: Entwicklung der GPT-Serie

Quelle: nach eigener Darstellung in Anlehnung an Zhao u. a. 2023, S. 9

## 6.2 Die Marktforschung

Die Disziplin der Marktforschung (Mafo) ist eines der am längsten etablierte Teilgebiete der Marketingwissenschaften (Kreis/Wildner/Kuß 2021, S. 1), die sich im Kern auf die Erklärung, Beschreibung, Prognose sowie Gestaltung von Austauschbeziehungen beruft (Lippold 2015, S. 1). Die Mafo ist unmittelbar mit dem Marketing verbunden, da sowohl die Ausrichtung von Angeboten verschiedener Unternehmen auf Kundenwünsche als auch die Beeinflussung der Kunden durch Unternehmen angemessene Kenntnisse über Kunden und Märkte erfordert. Im Gegensatz zu lokalen Einzelhändlern, die Kundenwünsche unmittelbar vor Ort erfahren, weisen größere Unternehmen selten einen direkten Kontakt zu Endkunden auf, was eine Informationsgewinnung erheblich erschwert. Folgendermaßen ist ein effizientes System zur „Sammlung und Aufbereitung von Marktinformationen – eben die Marktforschung -“ (Kreis/Wildner/Kuß 2021, S. 1) notwendig. Homburgs (2020, S. 250) Verständnis der Mafo dient als eine prägnante Definition des komplexen und umfassenden Fachgebiets: „*Unter Marktforschung verstehen wir die systematische Sammlung, Aufbereitung, Analyse und Interpretation von Daten über Märkte (Kunden und Wettbewerber) zum Zweck der Fundierung von Marktentscheidungen.*“ Dies beinhaltet die Entwicklung von Methoden zur Informationssammlung, die Planung und Durchführung der Datenerhebung, die Analyse sowie die Präsentation der Ergebnisse und der resultierenden Schlussfolgerungen (Kreis/Wildner/Kuß 2021, S. 1–2). Die Mafo zeichnet sich durch die systematische Nutzung wissenschaftlicher Forschungsmethoden aus, wobei Verfahren aus den Wissenschaften der Psychologie, der Soziologie und der Statistik auf den betriebswirtschaftlichen Mafo-Kontext angewandt werden (Koch/Riedmüller 2021, S. 7). Dementsprechend hat die Mafo nicht nur eine umfassende Beschreibung von Märkten, sondern die Erlangung von Erkenntnissen über Ursache-Wirkungs-Beziehungen zum Ziel (Böhler u. a. 2022, S. 15). Darüber hinaus besitzen der Datenschutz und die Sicherstellung von Anonymität eine entscheidende Bedeutung in der Mafo, sodass ein



Rückschluss auf einzelne Teilnehmer dahingehender Studien nicht möglich ist (Koch/Riedmüller 2021, S. 7). In der Praxis der Mafo erfolgt eine Differenzierung zwischen quantitativer und qualitativer Forschung. Erstere fokussiert sich auf die Beschreibung und Messung des Verhaltens und Denkens der Studienteilnehmer, z. B. durch Erfassung von Größen und Häufigkeiten, das Testen von Theorien mittels großangelegter, standardisierter Studien und die anschließende Datenanalyse mithilfe statistischer Methoden. Dagegen strebt die qualitative Forschung an, das Verhalten und Denken vielmehr ganzheitlich zu verstehen und zu interpretieren (Haselhoff/Holzmüller 2016, S. 586–587). Sie setzt damit das „Erkennen, Beschreiben und Verstehen psychologischer und soziologischer Zusammenhänge“ (Kepper 2008, S. 178) in den Vordergrund, weshalb sie bei explorativen Fragestellungen Anwendung findet (Haselhoff/Holzmüller 2016, S. 586).

## **7. KI und ChatGPT in der Marktforschung**

In diesem Kapitel werden die Potenziale der KI, insbesondere des Sprachmodells ChatGPT, in der Marktforschung (Mafo) betrachtet. Zudem werden Einblicke in die Grenzen der Sprachmodelle sowie in datenschutzrechtliche und ethische Aspekte im Umgang mit diesen eröffnet.

### **7.1 Potenziale von Künstlicher Intelligenz in der Marktforschung**

In diversen Studien wird das Potenzial von KI hinsichtlich einer Revolutionierung der Mafo betrachtet. Die KI ist in der Lage, zahlreiche Aspekte in der Mafo zu optimieren (Drăghici u. a. 2023, S. 41), sowohl in der quantitativen als auch in der qualitativen Forschung (Weber 2024; Woppmann 2024). Der praktische Einsatz von KI in der Mafo verstärkte sich mit einer verbesserten Rechenleistung und der wachsenden Verfügbarkeit hoher Datenmengen in den letzten zehn Jahren erheblich (Drăghici u. a. 2023, S. 42; Gentsch 2018, S. 71). KI-Anwendungen eignen sich insbesondere für eine schnellere, kostengünstigere und gründlichere Auswertung des gesamten Datenmaterials, wodurch Forschende befähigt werden, sich auf die entscheidenden Detailfragen zu fokussieren (Gentsch 2018, S. 71–72), „die zu einem besseren Kundenverständnis führen“ (Gentsch 2018, S. 73). Dadurch stellt die KI eine mittlerweile unverzichtbare Unterstützung dar und dient zudem als Assistent bei Entscheidungen (Weber 2024; Gentsch 2018, S. 72), sodass KI den Mafo-Prozess deutlich verbessert und beschleunigt (Mallikarjunaradhya/Pothukuchi 2021, S. 445). Zudem findet KI Anwendung in der Analyse des Kundenverhaltens, von Markttrends und bei der Prognose zukünftiger Marktbedingungen, die eine entscheidende Rolle für den Aufbau von Wettbewerbsvorteilen spielen (Mallikarjunaradhya/Pothukuchi 2021, S. 445). Mithilfe von KI werden spezifische Zielgrup-

pen identifiziert und das digitale Verhalten von Konsumenten beobachtet, wodurch sich in bisher unerreichter Intensität Einsichten über Interessen, bevorzugte Marken und Einstellungen in sämtlichen Lebensaspekten analysieren lassen. Die Anwendung von KI führt ebenfalls im qualitativen Bereich zu einer Effizienzsteigerung des Forschungsprozesses. Beispielsweise löst KI das menschliche Codieren ab, indem die Codierung offener Nennungen automatisiert wird und unterstützt bei der Entwicklung von Fragebogenleitfäden sowie bei der Auswertung von Protokollen und Transkripten (Weber 2024; Woppmann 2024; Karty 2024). Demenstprechend ermöglicht der Einsatz von KI die Herangehensweise, wie Marktforscher bisher Daten gesammelt und analysiert haben, auf eine neue und innovative Art zu transformieren (Karty 2024). Eine Voraussetzung für den Einsatz von KI bildet insbesondere die Einbeziehung und das Engagement der Mitarbeiter, denn nur wenn der Mehrwert der KI klar ersichtlich ist und ein grundlegendes Verständnis für sie besteht, ist eine erfolgreiche Nutzung und Entwicklung von KI-Anwendungen möglich (Terstiege 2021, S. 11).

## **7.2 Potenziale von ChatGPT in der Marktforschung**

Die Kernkompetenz von ChatGPT besteht darin, Prompts akkurat zu bewerten und menschenähnliche Antworten zu generieren, indem es sich auf sein Sprachverständnis stützt. Dies übt signifikante Auswirkungen auf die Mafo aus (Jain u. a. 2023, S. 3). ChatGPT unterstützt verschiedene Segmente der Mafo und weist das Potenzial auf, die Mafo-Praxis auf ein neues Niveau zu heben, indem präzisere Ergebnisse erzielt werden. Bereits in der Anfangsphase, insbesondere in der Ideenfindungsphase, erweist sich das Large-Language-Model (LLM) als nützlich. Forscher entwickeln mithilfe des LLMs kreative Konzepte und Ideen, indem sie ChatGPT mit bestimmten Prompts anregen. Hierdurch werden z. B. Hypothesen angepasst oder neue Forschungsthemen entwickelt, die zuvor unberücksichtigt blieben. Eines der zentralen Argumente für den Einsatz von ChatGPT in der Forschungspraxis ist seine Fähigkeit, große Textmengen effizient und schnell zu analysieren. ChatGPT ist dahingehend skalierbar und kann massive Datensätze sowie Forschungsinitiativen verarbeiten, weshalb es sich für Big-Data-Anwendungen eignet (Jain u. a. 2023, S. 2–4). Das Sprachmodell identifiziert nicht nur Muster, Trends und Konzepte in Daten, sondern ebenfalls Stimmungen, beispielsweise in Kundenrezensionen oder Social-Media-Beiträgen. Forscher erhalten dadurch aufschlussreiche Erkenntnisse über das Verhalten sowie die Vorlieben der Verbraucher und nutzen diese für die Entwicklung von Marketingplänen oder Produkten. Dies erleichtert die Suche nach relevanten Informationen erheblich und befähigt Forscher dazu, sich auf die Schlüsseldaten zu konzentrieren und bessere Entscheidungen zu treffen. Zudem ist ChatGPT in der Lage, eine Vielzahl

an Sprachen zu übersetzen, wodurch es Marktforscher von sprachlichen Einschränkungen hinsichtlich ihrer Datensammlung befreit (Jain u. a. 2023, S. 3). Mit ChatGPT lassen sich insgesamt erhebliche Mühen und zeitliche Ressourcen bei Aufgaben wie Datenanalyse, Texterstellung, Zusammenfassung, Literaturrecherche sowie der Beantwortung von Anfragen einsparen (Lund/Ting 2023, S. 5). Dies sind nur einige der möglichen Einsatzgebiete von ChatGPT in der Mafo, wobei sich in der Praxis zahlreiche weitere finden lassen (Lund/Ting 2023, S. 5; Jain u. a. 2023, S. 4). Um das Potenzial von ChatGPT für die Mafo weiter zu erörtern, enthält Anhang 10 ChatGPTs eigene Antwort darauf, wie es die Mafo unterstützen kann.

### 7.3 Grenzen von Sprachmodellen und ChatGPT

Diverse LLMs wie ChatGPT beeindrucken mit ihrem umfassenden Sprachverständnis und ihrer Kompetenz bei einer Vielzahl an Anwendungsfällen. Nichtsdestotrotz ist anzuerkennen, dass keines der derzeitigen Sprachmodelle als unfehlbar zu betiteln ist (Sudirjo u. a. 2023, S. 286). Dementsprechend stehen Mafo-Unternehmen in der Verantwortung, ein Bewusstsein über die Grenzen und Herausforderungen im Umgang mit KI-Systemen zu erwerben (Bharatha 2023, S. 1). Dieses Verständnis ist maßgeblich für die Reduktion möglicher Probleme sowie für den effektiven Einsatz von LLMs (Anadkat/Schulhoff/Yanni o. J.). Zudem sind die aktuellen Defizite der KI zu berücksichtigen, um sie „entsprechend mit menschlichen Kompetenzen zu ergänzen.“ (Steinmann/Piazza 2024, S. 413) Im Folgenden werden drei bedeutsame Risiken betrachtet, die ebenfalls mit ChatGPT assoziiert werden (Jain u. a. 2023, S. 5–6).

*Bias (Verzerrung bzw. Voreingenommenheit):* Bezeichnet die aufgrund persönlicher Merkmale wie Geschlecht oder Rasse ungerechte und systematische Behandlung von Gruppen oder Einzelpersonen. Trotz Sicherheitsvorkehrungen treten diese in LLMs in verschiedener Weise auf, indem z. B. Ausgaben generiert werden, die bestimmte Menschen diskriminieren oder Stereotype aufrechterhalten (Koubaa u. a. 2023, S. 19; Beattie u. a. 2022, S. 117–123). Dies lässt sich auf die Trainingsdaten zurückzuführen, auf denen LLMs basieren, wobei es durch die Masse an Textdaten nicht auszuschließen ist, dass diese Biases enthalten. Im Fall von GPT-4 ist zudem unbekannt, welche Trainingsdaten von OpenAI verwendet wurden, sodass keine Transparenz über mögliche Biases besteht (O’Neill/Connor 2023, S. 8). Voreingenommene LLMs tendieren vermehrt zu einer Bereitstellung von verzerrten, unvollständigen und ungenauen Informationen (Koubaa u. a. 2023, S. 20; Chui/Roberts/Yee 2022b), weshalb in geschäftskritischen Anwendungen ein Verifikationsprozess der Ergebnisse unumgänglich ist (Anadkat/Schulhoff/Yanni o. J.).

*Halluzinationen und generative Wahrscheinlichkeit:* Sprachmodelle wie ChatGPT weisen das Phänomen der Halluzination auf, indem sie eine Antwort generieren, die zwar strukturell korrekt erscheint, jedoch faktisch falsch und ungenau ist (Backus u. a. 2023, S. 301; Sohail u. a. 2023, S. 14; Chui/Roberts/Yee 2022b). In diesem Kontext besitzt ChatGPT keinen integrierten Mechanismus, um seine Antwort zu hinterfragen (OpenAI u. a. 2024, S. 10; Chui/Roberts/Yee 2022b). Die irreführenden Narrative werden insbesondere von Nutzern ohne Expertise als legitim missverstanden (Sohail u. a. 2023, S. 14). Halluzinationen sind auf die Vorgehensweise zurückzuführen, wie LLMs den Sprachgebrauch lernen (Kaddour u. a. 2023, S. 20). Während des Trainings ordnen LLMs weniger die Bedeutungen der Wörter zu, als vielmehr die statistischen Regelmäßigkeiten zu lernen, wie Sätze und Wörter typischerweise gemeinsam auftreten. Somit verstehen LLMs die Bedeutung hinter Prompts sowie den Text, den sie selbst generieren, im Grunde nicht. Das Konzept der generativen Wahrscheinlichkeit führt dazu, dass die KI das nächste zu generierende Wort basierend auf dessen Wahrscheinlichkeit berechnet, wobei es vorkommt, dass bei der Auswahl des nächsten Wortes eine Reihe an gleichwertigen oder in vergleichbarer Häufigkeit vorkommenden Wortoptionen vorliegt. In diesem Fall wird eines dieser Wörter zufällig ausgewählt. Dies erklärt, weshalb ChatGPT bei Eingabe desselben Prompts unterschiedliche Ausgaben generiert. Die generative Wahrscheinlichkeit bedingt damit, in Verbindung mit dem fehlenden Verständnis für Semantik, die Generierung sinnloser und falscher Antworten (O’Neill/Connor 2023, S. 6–7).

*Begrenztes Wissen:* Während LLMs zwar eine umfangreiche Sammlung an Informationen aufweisen, haben sie keinen Zugriff auf sämtliches Wissen, über das Menschen verfügen, insbesondere Fachwissen. Demzufolge stoßen Sprachmodelle bei Aufgaben in einem spezialisierten Bereich an ihre Grenzen. Zusätzlich besitzen sie keine Informationen über kürzliche Entwicklungen (Marr 2023), da sie in ihren Trainingsdaten limitiert sind und oftmals keinen Internetzugang aufweisen (Anadkat/Schulhoff/Yanni o. J.). Im Fall von GPT-4 reicht die überwiegende Mehrheit der Trainingsdaten nur bis September 2021. Dadurch fehlt dem Modell das Wissen über Ereignisse nach diesem Zeitraum und es lernt darüber hinaus nicht aus seinen Erfahrungen (OpenAI u. a. 2024, S. 10).

#### **7.4 Datenschutz und Ethik**

Das Geschäft der Marktforschung (Mafo) basiert auf sensiblen, personenbezogenen Daten, weshalb im Hinblick auf datenschutzrechtliche und ethische Aspekte eine hohe Gewichtung auf die Frage der Vertraulichkeit gelegt wird (Kreis/Wildner/Kuß 2021, S. 323, 327). Zudem erfordert der Einsatz von KI, insbesondere in regulatorischen Kontexten wie der Europäischen

Union (EU) und im Zuge des „AI-Acts“, höhere rechtliche Anforderungen an das Datenmanagement und die Berücksichtigung ethischer Implikationen. Dementsprechend sind die folgenden Aspekte zu beachten, um einen sicheren Datenaustausch bei der Interaktion mit KI-Modellen zu gewährleisten (Törnberg 2024, S. 13).

*Transparenz und Einverständnis:* Betroffene sind über die Anwendung externer Dienste und die Auswirkungen auf ihre Daten in Kenntnis zu setzen. Dies beinhaltet die Einholung ihrer ausdrücklichen Zustimmung zur Verwendung personenbezogener Daten und die anschließende Analyse durch LLMs. Den Hintergrund bildet die insoweit hohe Wahrscheinlichkeit, dass Eingabedaten bei der Nutzung plattformbasierter LLMs wie ChatGPT in das Training der Modelle miteinfließen (Törnberg 2024, S. 13).

*Datenvereinbarung:* Werden Dienste von Drittanbietern wie OpenAI in Anspruch genommen, ist es ratsam, eine Datenverarbeitungsvereinbarung (Data-Processing-Agreement) abzuschließen. Diese dient zur Festlegung der Datenverungsverfahren, der Ziele der Datenverarbeitung sowie der Datenschutzvorkehrungen (Törnberg 2024, S. 13).

*Anonymisierung der Daten:* Weiterhin ist zu gewährleisten, dass sämtliche personenbezogenen Informationen, angemessen pseudonymisiert oder anonymisiert werden, bevor Daten an ein plattformgestütztes Sprachmodell weitergeleitet werden. Generellen ist zu vermeiden, dass vertrauliche oder geheime Daten, ohne eine vorherige sorgfältige und kritische Prüfung der rechtlichen und ethischen Implikationen an eine Webschnittstelle oder an eine API gesendet werden (Törnberg 2024, S. 14).

*Datenminimierung:* Es empfiehlt sich, die Datenverwendung und -weiterleitung auf ein Minimum zu reduzieren. Die Datenminimierung stellt nicht nur eine bedeutende ethische Richtlinie dar, sondern ist, als Teil der DSGVO, als rechtlicher Grundsatz verankert (Törnberg 2024, S. 14).

*Speicherung und Übertragung von Daten:* Unternehmen sollten beachten, wo die Datenspeicherung und die -verarbeitung erfolgen. Die DSGVO schreibt hierzu vor, dass die Datenübertragung außerhalb der EU und des Europäischen Wirtschaftsraums ausreichenden Schutzmaßnahmen unterliegen muss oder in Länder erfolgt, die ein angemessenes Datenschutzniveau aufweisen (Törnberg 2024, S. 14).

## 8. Prompt-Engineering in der Marktforschung

In diesem Kapitel wird die Thematik des Prompt-Engineering (PE) erläutert, die eine Grundlage für die nachfolgende empirische Untersuchung der Implikationen des PE auf die Marktforschung (Mafo) bildet.

### 8.1 Definition des Prompt-Engineering

Das Prompt-Engineering (PE) beschreibt ein interdisziplinäres Fachgebiet, das sich auf die systematische Optimierung von Prompts fokussiert, mit dem Ziel, zweckgerichtete und nützliche Ergebnisse von KI-Modellen zu erhalten, die sich des Natural-Language-Processing (NLP) bedienen. Ein Prompt stellt eine Eingabe in natürlicher Sprache für diese KI-Anwendungen dar, der die Anweisungen sowie den Kontext umfasst, um die Reaktion der KI zu navigieren (A.Shaji George/A. S.Hovan George 2023, S. 1). Der Prompt kann als eine Programmierung der Ausgaben eines Large-Language-Model (LLM) verstanden werden, wobei das PE vielmehr einer menschlichen Konversation gleicht als einem klassischen Programmierungsprozess (Weber/Reichardt 2023, S. 3). Die Fortschritte der letzten zehn Jahre auf dem Gebiet des NLP sind als Treiber für die Entstehung des PE als eigenständige Disziplin zu sehen (A.Shaji George/A. S.Hovan George 2023, S. 2), die „sich mit der Frage beschäftigt, wie Menschen mit KI zusammenarbeiten.“ (Steinmann/Piazza 2024, S. 405) Hierfür kombiniert PE Konzepte aus Bereichen der Informatik mit Prinzipien der Psychologie, der Kommunikation und der Linguistik. Das PE ist darauf ausgerichtet, die Grenzen und Stärken einer KI-Anwendung zu verstehen. Demzufolge beschränken effiziente Prompts präzise den Problemraum, damit die KI jenen zuverlässig lösen kann (A.Shaji George/A. S.Hovan George 2023, S. 2). Somit stellt PE eine entscheidende Fähigkeit für die Zusammenarbeit mit LLMs wie ChatGPT dar, da es maßgeblich bestimmt, wie das Modell die Eingaben verstehen und folglich reagieren soll (Gotts 2023). Effektive Prompts sind daran zu erkennen, dass sie den Rahmen der Aufgabe schildern, die Anweisungen klar benennen und das KI-System auf den gewünschten Inhalt sowie das Antwortformat abstimmen. Abbildung 3 stellt die vier grundlegenden Elemente eines Prompts dar. Hierbei ist zu beachten, dass ein Prompt nicht alle Elemente benötigt, da die Strukturierung und Formulierung von der jeweiligen Aufgabenstellung abhängt (Saravia 2024). Zur Standardisierung gängiger Anwendungsfälle bietet sich die Möglichkeit, Vorlagen für Prompts, sogenannte Prompt-Frameworks (PF), zu erstellen (A.Shaji George/A. S.Hovan George 2023, S. 2). Dieses Vorgehen wird fortführend in Kapitel 8.4 beschrieben.

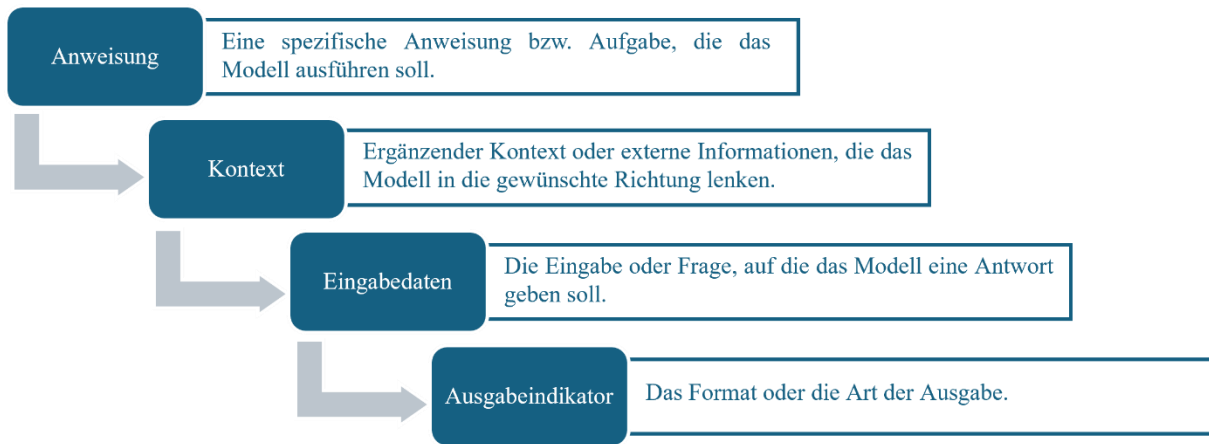


Abbildung 3: Elemente eines Prompts

Quelle: nach eigener Darstellung in Anlehnung an IBM Documentation 2024a; Saravia 2024

## 8.2 Relevanz von Prompt-Engineering

Das Feld der KI und insbesondere die NLP-Landschaft sind durch die Entwicklung von LLMs revolutioniert worden. In diesem Zuge wurde festgestellt, dass die Skalierung von LLMs eine verbesserte Leistung erbringt. Allerdings erweist sich die Skalierung allein als nicht ausreichend, um bei anspruchsvollen Problemstellungen eine hohe Leistung zu erzielen (Wei u. a. 2023, S. 2). Dies führte zu einem steigenden Interesse an der Verbesserung ihrer Fähigkeit, Aufgaben mithilfe einer gezielten Formulierung von Prompts zu lösen (Wei u. a. 2023, S. 24). Folglich entwickelte sich die Disziplin des PE parallel zu LLMs weiter. Ursprünglich als eine grundlegende Praxis für die Gestaltung von Prompts zur Steuerung der generierten Ergebnisse beginnend, hat sich das PE als systematisches Forschungsgebiet etabliert. Dieses weist inzwischen zahlreiche Methoden und bewährte Strategien vor (Chen u. a. 2023, S. 2), die im nachfolgenden Kapitel 8.3 beleuchtet werden. Studien wiesen nach, dass die Qualität der Modellausgaben durch den bereitgestellten Prompt signifikant beeinflusst wird, wobei die Konstruktion der Eingabe zu erheblichen Leistungsunterschieden führt (Chen u. a. 2023, S. 2; Steinmann/Piazza 2024, S. 405). Änderungen in der Struktur, wie die Länge des Prompts, und im Inhalt üben einen entscheidenden Einfluss auf die Antworten des Sprachmodells aus. Diverse Arbeiten verdeutlichen, dass Prompts LLMs auf unerwartete Weise beeinflussen, sodass die Sensibilität gegenüber der genauen Prompt-Gestaltung eines der bedeutsamsten Kriterien für die Interaktion mit ihnen darstellt (Wei u. a. 2023, S. 17). Die Formulierung sowie die Reihenfolge, der im Prompt enthalten Beispiele, üben einen signifikanten Einfluss auf das Verhalten des Modells aus (Chen u. a. 2023, S. 2). Zudem ist PE insbesondere für die Interaktion mit ChatGPT entscheidend, da es einen dialogischen Ansatz

verfolgt (Manghani 2024). Das PE dient im Wesentlichen der Sicherstellung der Relevanz, Genauigkeit und Konsistenz der Modellergebnisse. Das Vorgehen des PE ist von ausschlaggebender Bedeutung für die Ausschöpfung des vollen Potenzials von LLMs und ermöglicht eine höhere Zugänglichkeit für verschiedene Anwendungsgebiete. Studien heben außerdem hervor, dass Prompts, die unter Beachtung von PE-Methoden konstruiert wurden, Herausforderungen von LLMs entgegenwirken, wie das Halluzinieren und Biases (Kelbert 2024; Chen u. a. 2023, S. 2; Pawlan 2023). Durch eine präzise Gestaltung der Prompts wird das Modell zu einer objektiveren und ausschließlich auf Fakten basierenden Antwort geführt (Pawlan 2023). Somit unterstreicht der Aufstieg des PE die Erforderlichkeit einer menschlichen Führung für die Maximierung der Nutzung von KI (A.Shaji George/A. S.Hovan George 2023, S. 3). Darüber hinaus sind Unternehmen zunehmend bestrebt, LLMs in ihre Arbeitsmethoden sowie in ihre Produkte zu integrieren. Eine Studie des „Forbes Technology Council“ präsentierte, dass 90% der Unternehmen, die NLP-Systeme implementieren, aufgrund von minderwertigen Prompts weniger als 50% des angestrebten Wertes erreichen. Weiterhin gibt die Studie an, dass 67% der Führungskräfte als größte Herausforderung im Einsatz mit KI die fehlende PE-Expertise werten (A.Shaji George/A. S.Hovan George 2023, S. 6). Dementsprechend werden Prompt-Engineers, Experten im Gebiet des PE, entscheidend für die erfolgreiche Einführung der LLMs in Unternehmen sein: Sie übernehmen die Rolle eines Multiplikators für Unternehmen, indem sie die KI-Modelle für die Bewältigung manueller Aufgaben befähigen oder neue KI-Produkte entwickeln. Hierbei lässt sich ein Trend zur Einstellung von Personen erkennen, die Kompetenzen im PE besitzen, wobei geschätzt wird, dass die globale Nachfrage nach PE jährlich um mehr als 20% wachsen wird (A.Shaji George/A. S.Hovan George 2023, S. 1–2; Sloyan 2023).

### **Relevanz von Prompt-Engineering für die Marktforschung**

Zahlreiche Studien belegen die Nützlichkeit und Effektivität des PE für die Optimierung KI-generierter Ergebnisse (A.Shaji George/A. S.Hovan George 2023, S. 3). Zwar finden sich in diesem Zusammenhang kaum wissenschaftliche Arbeiten, die die Anwendung von PE spezifisch in der Mafo betrachten. Jedoch ist zu beobachten, dass sich das PE in der Praxis der Mafo als eine Fähigkeit etabliert, um das volle Potenzial von LLMs für Marktforschungszwecke auszuschöpfen (Sawtooth Software 2024). Zudem findet das PE bereits eine weite Anwendung in den verwandten Gebieten des Marketings und des Vertriebs, indem Prompt-Engineers beispielsweise die Nutzung von Kundendaten für „personalisierte Empfehlungen und Segment-Targeting“ (A.Shaji George/A. S.Hovan George 2023, S. 5) optimieren. Das PE stellt



gemäß Budhiya (2024) einen entscheidenden Aspekt bei der Zusammenarbeit mit LLMs in der Mafo dar. Einer der zentralen Beweggründe dessen findet sich im kontextuellen Verständnis: Durch eine effektive Strukturierung der Prompts wird sichergestellt, dass die KI den Kontext der Frage versteht, was zu besseren und relevanteren Antworten führt (Bhudiya 2024). Fähigkeiten im PE unterstützen Marktforscher z. B. darin, aussagekräftigere Erkenntnisse aus Umfragen zu gewinnen (A.Shaji George/A. S.Hovan George 2023, S. 5). Die im Rahmen dieser Arbeit durchgeführten Experteninterviews greifen das Forschungsdefizit auf, um ein tiefgreifendes Verständnis für die Relevanz des PE für die Mafo zu gewinnen.

### **8.3 Methoden und Strategien des Prompt-Engineering**

Das PE bietet ein breites Spektrum an Techniken, das von „grundlegenden Ansätzen wie dem Role-Prompting bis hin zu anspruchsvolleren Methoden wie dem Chain-of-Thought-Prompting reicht“ (Chen u. a. 2023, S. 2), die zur Optimierung der Ergebnisse dienen. Hierbei ist zu beachten, dass sich das Gebiet des PE durch seine Dynamik auszeichnet und fortwährend neue Techniken und Anwendungen in Studien aufkommen (Chen u. a. 2023, S. 2). Bevor der Prozess des PE begonnen wird, ist zu berücksichtigen, dass dieser Vorgang ein iteratives Verfahren darstellt, das einen hohen Experimentiergrad erfordert, um Ergebnisse zu erreichen, die auf den jeweiligen Anwendungsfall abgestimmt sind (OpenAI o. J.d; Saravia o. J.a). In dieser Arbeit erfolgt eine Strukturierung der PE-Ansätze in grundlegende Empfehlungen für die Optimierung der Prompts, bewährte PE-Strategien sowie die Beeinflussung der Large-Language-Model-Einstellungen. Weitere Strategien, die von OpenAI empfohlen werden, finden sich ergänzend in Anhang 11.

#### **8.3.1 Optimierung von Prompts**

Die Fähigkeit, präzise und effiziente Prompts zu schreiben, ist unerlässlich zur Gewinnung qualitativ hochwertiger und zielgerichteter Ergebnisse bei einer Zusammenarbeit mit Large-Language-Models (LLMs) wie ChatGPT (Steinmann/Piazza 2024, S. 405). Es lassen sich bereits durch die Einbeziehung weniger Schlüsselkriterien, elementare Prompts entwickeln, die wertvolle Ergebnisse generieren (Chen u. a. 2023, S. 3). Im Folgenden werden einige Kriterien für strukturierte und zuverlässige Prompts beleuchtet, die ebenfalls von OpenAI für die Prompt-Formulierung innerhalb ihrer Application-Programming-Interfaces (APIs) empfohlen werden (OpenAI o. J.e).

*Klare Anweisungen:* Da die Antworten von LLMs wie ChatGPT ausschließlich auf den zur Verfügung gestellten Prompts basieren, ist es ratsam, die Anweisungen mit Präzision und

Klarheit zu formulieren. Bei unklaren oder mehrdeutigen Formulierungen wird es indessen der KI überlassen, die Anweisung zu interpretieren (OpenAI o. J.e). Beispielsweise tendiert das GPT-4-Modell zu Ausgaben, die einen überwiegend generischen Charakter aufweisen, wenn es mit unspezifischen Prompts ohne ergänzende Details konfrontiert wird (Chen u. a. 2023, S. 3). Dies mindert die Nützlichkeit und Relevanz der Ergebnisse, insbesondere in spezifischen Domänen. Dagegen leitet eine präzise und detaillierte Gestaltung des Prompts LLMs dazu an, Ergebnisse zu generieren, die an die individuellen Anforderungen der auszuführenden Aufgabe angepasst sind. Somit wird das Verhalten des Modells in die gewünschte Richtung gesteuert (Chen u. a. 2023, S. 3–4). Des Weiteren empfiehlt es sich, die Art der Ausgabe im Prompt spezifisch zu definieren, indem Faktoren wie der Stil, das Format und die Länge für die gewünschte Antwort festgelegt und durch Beispiele unterstrichen werden (OpenAI o. J.d). Dies führt zu einer deutlichen Qualitätssteigerung der generierten Antworten (OpenAI o. J.e).

*Bereitstellung von Referenztexten:* Gelegentlich generieren LLMs ungenaue oder falsche Antworten, oftmals in Fällen, in denen nach Zitaten oder Web-Adressen gefragt wird. Insofern erweist es sich als sinnvoll, relevante Referenztexte in Prompts bereitzustellen, die zuverlässige und vertrauenswürdige Informationen enthalten. Mit deren Hilfe wird das Modell in eine beabsichtigte Richtung gelenkt, indem es angewiesen wird, den Referenztext für die Generierung seiner Ergebnisse zu verwenden. Da LLMs über ein begrenztes Kontextfenster verfügen, ist es notwendig, dem Modell eine Möglichkeit für die dynamische Suche nach Informationen anzubieten, die für die Anweisung relevant sind. Mit der Einbettung entsprechender Dokumente wird ein effizienter Wissensabruf realisiert und gleichzeitig die Wahrscheinlichkeit für fehlerhafte Ausgaben, d. h. Halluzinationen, verringert. Das LLM kann beispielsweise dazu aufgefordert werden, Zitate aus diesem Text in seinen Antworten zu integrieren (OpenAI o. J.e).

*Aufteilung komplexer Aufgaben in Teilaufgaben:* Die in der Softwareentwicklung übliche Praxis, komplexe Systeme in Teilkomponenten zu zerlegen, um die Bearbeitung zu erleichtern, lässt sich ebenfalls auf Prompts übertragen. Denn komplexe Aufgaben weisen hierbei eine tendenziell höhere Fehlerquote auf als vergleichbar triviale Aufgaben. Mithin ist es von Vorteil, komplexe Aufgabenstellungen als eine Reihe verständlicherer Aufgaben zu formulieren (OpenAI o. J.e). Zudem verhindert dies die Zuführung von zu viel Komplexität zu Beginn der Prompt-Gestaltung. Generell wird empfohlen, mit unkomplizierten Prompts zu beginnen und

iterativ weiteren Kontext und Elemente zu ergänzen, um präzisere Ergebnisse anzustreben. Das schrittweise Iterieren des Prompts ist aus diesem Grund maßgeblich (Saravia o. J.a).

### 8.3.2 Prompt-Engineering-Strategien

Das PE umfasst eine Vielzahl an Strategien, die zu aussagekräftigen Ergebnissen führen. Zu den erfolgversprechendsten Strategien zählen das Few-Shot-Prompting (FS), als Bestandteil des Shot-Prompting (SP), und das Chain-of-Thought-Prompting (CoT), das bei einer Mehrheit der LLMs zu konsistenten und nützlichen Ergebnissen führt (Mollick 2023). Zudem wird das Role-Prompting (RP) als eine weitere PE-Strategie beleuchtet, die in der Literatur und in der Praxis vielfach Beachtung findet (Chen u. a. 2023, S. 4). Dementsprechend richtet sich der Fokus dieser Arbeit auf diesen drei Strategien. Dabei werden RP und SP als grundlegende Strategien des PE gewertet, während sich das CoT auf einem fortgeschritteneren Niveau bewegt (Chen u. a. 2023, S. 2). Zudem besteht die Möglichkeit, eine Kombination aus unterschiedlichen Strategien zu bilden, um zu besseren Ergebnissen zu finden. Beispielsweise kann das FS mit CoT zu einem gemeinsamen Ansatz kombiniert werden, der eine erheblich stärkere Leistung gegenüber dem regulären FS aufweist (Weber/Reichardt 2023, S. 4–5).

#### Role-Prompting

Das RP stellt eine fundamentale Strategie im Rahmen des PE dar. Hierbei wird dem Sprachmodell eine spezifische Rolle zugewiesen, etwa die eines fachkundigen Experten (Chen u. a. 2023, S. 4). Fortschrittliche LLMs wie ChatGPT bereichern mit ihren Rollenspielfähigkeiten die Nutzererfahrung und schaffen neue Interaktionsmöglichkeiten. Sie sind in der Lage, verschiedene Persönlichkeiten, von historischen bis zu fiktiven Charakteren, überzeugend nachzuahmen, wobei die zugewiesene Rolle Aufschluss über den Hintergrund sowie die Identität des Modells gibt (Kong u. a. 2023, S. 1). Das RP qualifiziert sich insbesondere zur Lenkung der Ausgaben des Modells und zur Sicherstellung, dass die Antworten mit dem gewünschten Ergebnis übereinstimmen (Chen u. a. 2023, S. 4–5). Diverse Arbeiten weisen eine deutliche Verbesserung der Leistung durch RP bei bestimmtem NLP-Aufgaben nach (Wang u. a. 2024, S. 2). Indem das LLM die Persona annimmt, wird es „natürlichere, auf die Rolle zugeschnittene Antworten geben“ (Kong u. a. 2023, S. 2). Mit der Annahme einer Expertenrolle, wird das Modell folglich mit einer höheren Wahrscheinlichkeit zu einer kontextgenaueren und detaillierteren Antwort angeleitet, wenn es zum jeweiligen Fachgebiet befragt wird (Chen u. a. 2023, S. 4–5). Zusätzlich verbessert das RP die komplexen Argumentationsfähigkeiten (Reasoning-Abilities) von LLMs, ähnlich dem CoT (Kong u. a. 2023, S. 7).

## Shot-Prompting

Das SP vereint PE-Techniken, die sich auf die Qualität und Quantität des im Prompt enthaltenen Kontexts konzentrieren. Es bildet bei der Kooperation mit LLMs wie ChatGPT eine verbreitete Praxis, indem es die Effektivität und Qualität der Ausgaben sowie das Verständnis des Modells beeinflusst. Zu den wesentlichen Ansätzen des SP zählen Zero-, One- und Few-Shot-Prompting (Skill Leap AI 2023; IBM o. J.c). Diese werden als der Grad verstanden, in dem die KI auf aufgabenspezifische Daten zurückgreift (Weber/Reichardt 2023, S. 4). Abbildung 4 verdeutlicht die Prompt-Struktur der drei SP-Techniken anhand eines Beispiels.

*Zero-Shot-Prompting (0S)*: Die Bezeichnung 0S bedeutet, dass dem LLM ein Prompt eingegeben wird, in der die Aufgabe, ohne weitere zur Verfügung gestellte Beispiele, beschrieben wird (Brown u. a. 2020, S. 7). Das Modell ist hierbei nicht explizit auf diese Aufgaben trainiert, wodurch das 0S die Fähigkeit des Modells bewertet, relevante Antworten zu generieren, ohne von vorherigen Beispielen abhängig zu sein (IBM o. J.c). Gemäß Brown u. a. (2020, S. 7) stellt 0S die bequemste Methode für die Prompt-Eingabe dar. Jedoch birgt diese Technik die größte Schwierigkeit, da sie nicht auf sämtliche Aufgabenarten anwendbar und in einigen Fällen durch ihre fehlenden Beispiele kontraproduktiv ist (Weber/Reichardt 2023, S. 4; Brown u. a. 2020, S. 7).

*One-Shot-Prompting (1S)*: Das 1S ergänzt die Anweisung im Prompt um exakt ein Beispiel, das zu einem optimaleren Verständnis des Inhalts und des Aufgabenformats beiträgt. Dadurch wird das Modell mit einer begrenzten Anzahl an Informationen in die gewünschte Lösungsrichtung gelenkt, was wiederum ein genaueres Ergebnis erzielt (Weber/Reichardt 2023, S. 4; Brown u. a. 2020, S. 4).

*Few-Shot-Prompting (FS)*: Das FS, ebenfalls bekannt als „In-Context-Learning“ (IBM o. J.c), unterscheidet sich vom 1S lediglich in der Anzahl an bereitgestellten Demonstrationen (Brown u. a. 2020, S. 6). Die Funktionsweise von FS wird von Brown u. a. (2020, S. 6) folgendermaßen beschrieben: „[...] few-shot works by giving K examples of context and completion, and then one final example of context, with the model expected to provide the completion“. Zu den maßgeblichen Vorteilen des FS zählt eine deutlich verringerte Abhängigkeit von aufgabenspezifischen Daten (Brown u. a. 2020, S. 6). Zusätzlich zeigen die Testergebnisse von Brown u. a., dass das FS zu insgesamt besseren Ergebnissen führt (Weber/Reichardt 2023, S. 4). Im Gegensatz zu 0S und 1S, die in der Regel generische Ergebnisse bereitstellen, da sie nicht auf die spezifischen Anforderungen zugeschnitten sind, erlaubt das FS eine An-

passung der Ausgaben an das betreffende Anwendungsszenario (Skill Leap AI 2023). OpenAI empfiehlt in seinem Leitfaden „Best practices for Prompt Engineering with OpenAI API“, zunächst mit OS zu beginnen und zu FS zu wechseln, falls die erstere Methode nicht die gewünschten Ergebnisse erzielt. Versagen beide Ansätze, sollte eine Feinabstimmung (Fine-Tuning) genutzt werden (OpenAI o. J.d). In diesem Zusammenhang findet sich zur Vertiefung der Thematik eine Gegenüberstellung von PE im Vergleich zur Feinabstimmung in Anhang 13.

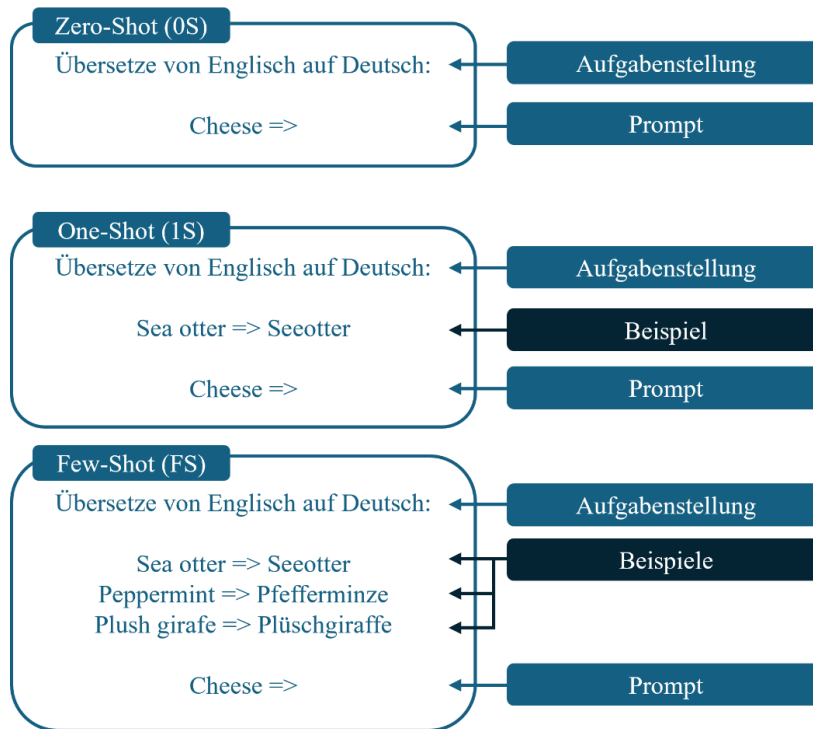


Abbildung 4: Gegenüberstellung von Zero-, One- und Few-Shot-Prompting am Beispiel einer Übersetzungsaufgabe

Quelle: nach eigener Darstellung in Anlehnung an Brown u. a. 2020, S. 7

### Chain-of-Thought-Prompting

Large-Language-Models (LLMs) offenbaren eine höhere Wahrscheinlichkeit von kognitiven Fehlern, wenn sie zu einer sofortigen Antwort aufgefordert werden, anstatt ihnen Zeit zum Nachdenken einzuräumen. Das CoT begegnet dieser Herausforderung, indem es sich nach der „Gedankenkette“ des Modells erkundigt, bevor es eine finale Antwort generiert (OpenAI o. J.e). Die Strategie besteht aus einer Reihe von zwischengeschalteten Denkschritten, die den Denkprozess erleichtern und das Modell unterstützen, zu dem gewünschten Ergebnis zu finden (Wei u. a. 2023, S. 1, 3; Weber/Reichardt 2023, S. 3). Das CoT weist vorteilhafte Eigen-

schaften auf, die in der Summe zu konsistenteren Ausgaben führen (OpenAI o. J.e; Wei u. a. 2023, S. 3). Es ermöglicht dem LLM, mehrstufige Aufgaben in Zwischenschritte zu zerlegen, wodurch zusätzliche Rechenoperationen für Probleme freigesetzt werden, die eine höhere Anzahl an Denkschritten benötigen. Des Weiteren wird durch CoT ein „interpretierbares Fenster in das Verhalten des Modells“ (Wei u. a. 2023, S. 3) eröffnet, das den Lösungsweg nachvollziehbarer gestaltet und die Fehlersuche bei einem inkorrektem Argumentationsweg erlaubt. Zudem eignet sich CoT für Aufgaben, die logisches Denken, symbolische Manipulation oder mathematische Wortprobleme beinhalten. In LLMs ist CoT zu erreichen, indem Beispiele für Gedankenketten-Sequenzen in das Few-Shot-Prompting (FS) einbezogen werden (Wei u. a. 2023, S. 3). Die Arbeit von Wei u. a. (2023, S. 9) verdeutlicht, dass CoT für zahlreiche Schlussfolgerungsaufgaben eine höhere Effizienz als Standard-Prompting beweist und die Reihe an Aufgaben, bei denen LLMs imstande sind, diese erfolgreich zu lösen, zu erweitern scheint. Abbildung 5 bildet diesen Umstand ab, indem das LLM durch die Integration einer Gedankenkette in das FS zum korrekten Ergebnis geführt wird.

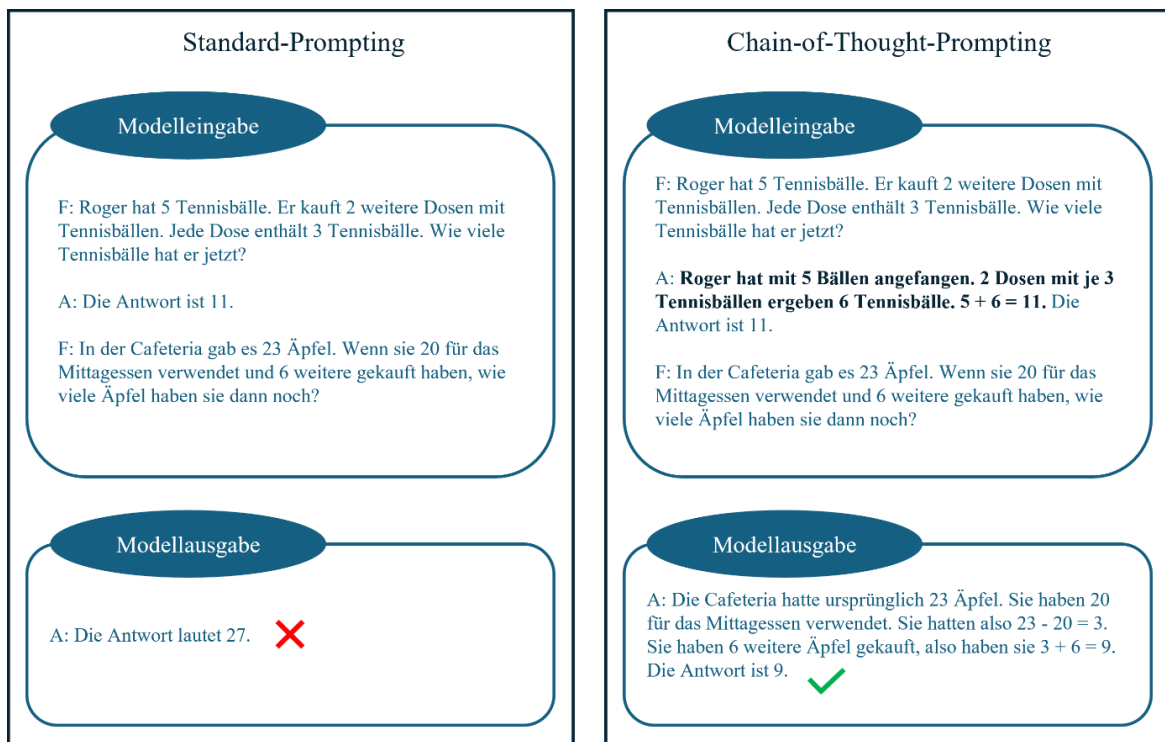


Abbildung 5: Gegenüberstellung von Standard-Prompting und Chain-of-Thought-Prompting im Few-Shot-Prompting

Quelle: nach eigener Darstellung in Anlehnung an Wei u. a. 2023, S. 1

### 8.3.3 Large-Language-Model-Einstellungen

Für einen effizienten Einsatz von LLMs ist als weiteres Element des PE zu berücksichtigen, wie die Parameter des Sprachmodells eingestellt sind. Diese beeinträchtigen die Ergebnisse der Prompts maßgeblich, indem die Optimierung der Parameter entscheidend für die Gewährleistung der Erwünschtheit und Zuverlässigkeit der Ausgaben ist. Für die Entwicklung und das Testen von Prompts erfolgt die Interaktion mit dem LLM in der Regel über ein Application-Programming-Interface (API) (Saravia o. J.b). Abbildung 6 stellt eine Übersicht der verschiedenen LLM-Parameter und ihrer Funktionsweisen dar. Zusätzlich ist eine detailliertere Ausführung dieser Parameter in Anhang 12 zu finden. Unter den Einstellungen werden überwiegend das Modell und die Temperatur berücksichtigt, um die Ausgaben des LLM zu steuern (OpenAI o. J.d).

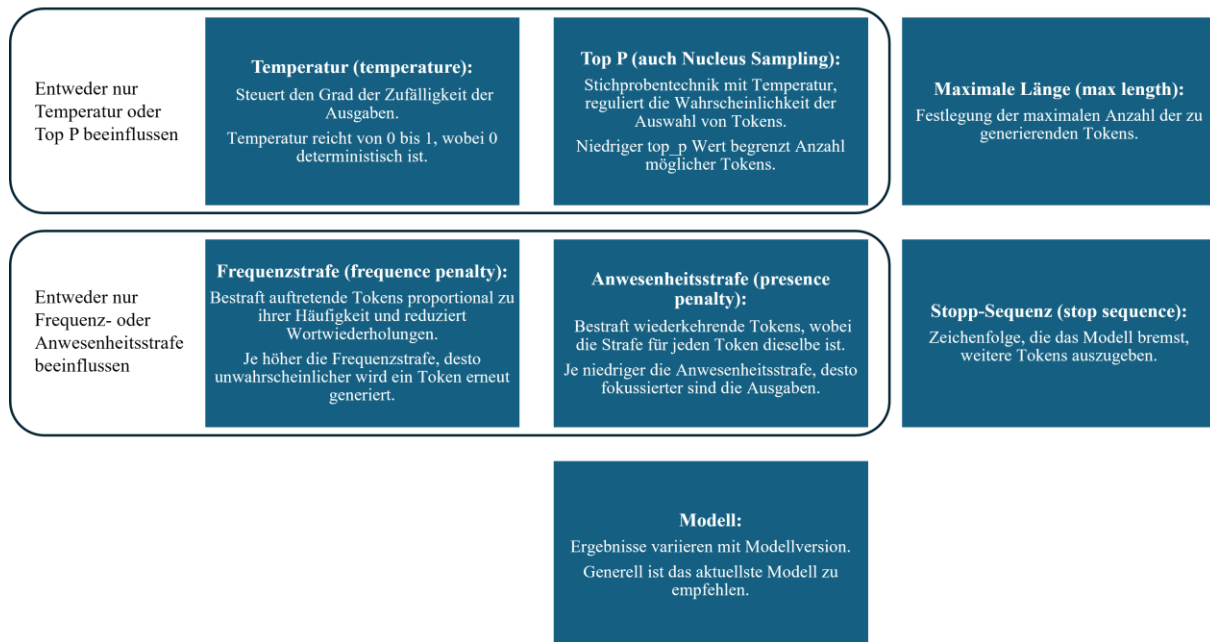


Abbildung 6: Übersicht über Large-Language-Model-Einstellungen

Quelle: nach eigener Darstellung in Anlehnung an Törnberg 2024, S. 13; OpenAI o. J.d; Saravia o. J.b

### 8.4 Prompt-Framework

Der maßgebliche Faktor für die Entfaltung des vollen Potenzials von LLMs liegt nicht allein in ihrer Modellkomplexität, sondern vielmehr in der Methodik, wie Anwender mit ihnen interagieren. Angesichts der zentralen Bedeutung, die der Formulierung von Prompts zukommt, ist ein strukturiertes Vorgehen bei ihrer Erstellung zu berücksichtigen. Prompt-Frameworks (PFs) setzen hier an, indem sie als Leitfäden die Optimierung der Interaktion mit LLMs an-

streben. Sie zeichnen sich durch eine systematische Methode für die Prompt-Entwicklung aus, die gewährleistet, dass die Anweisungen zielgerichtet und klar gestaltet sind (Severino 2024; Youngblood 2023). Insbesondere ist dies von Vorteil für Bereiche, mit hohen Ansprüchen an die Präzision der Ergebnisse (Severino 2024). Des Weiteren trägt die Verwendung von PFs zur Verbesserung der Benutzererfahrung bei, indem diese für Anwender, die erstmalig mit der Disziplin des PE in Berührung kommen, als Orientierungshilfe dienen. Außerdem eröffnen sie die Möglichkeit der Skalierbarkeit und Standardisierung, indem die PFs wiederkehrend verwendet und geteilt werden (Severino 2024; IBM Documentation 2024b). Innerhalb von Unternehmen dienen PFs als „einheitliche Sprache“ (Severino 2024), die sicherstellt, dass die Mitarbeiter das LLM konform zu den Unternehmensrichtlinien nutzen (Severino 2024). Im PE finden sich zahlreiche Ansätze für verschiedene Framework-Formate. In dieser Arbeit wird das RISE-Framework als exemplarischer Ansatz betrachtet, das insbesondere für Modelle wie ChatGPT empfohlen wird (Mustafa 2024). Das RISE-Framework bietet einen „methodischen Ansatz, um Aufgaben zu definieren, wichtige Informationen anzubieten, umsetzbare Schritte zu beschreiben und explizite Erwartungen zu formulieren.“ (Mustafa 2024) Dabei bildet RISE ein Akronym für Role, Input, Steps und Expectation (Mustafa 2024), die im Folgenden ausgeführt werden. Abbildung 7 dient als Veranschaulichung, wie ein Prompt nach dem RISE-Framework entwickelt werden kann.

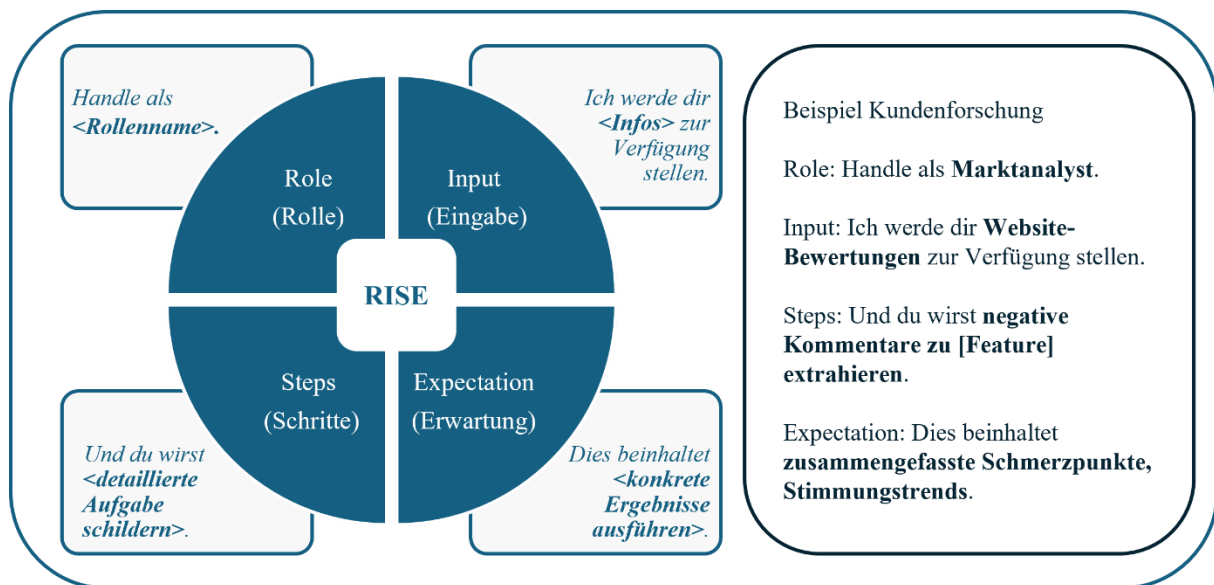


Abbildung 7: Beispiel für einen Prompt nach dem RISE-Framework

Quelle: nach eigener Darstellung in Anlehnung an Prompthaton (siehe Anhang 14) und Mittal 2024



*Role:* Die spezifische Zuteilung einer Rolle an das LLM, dient als Orientierung, wie es die Aufgabe auffasst. Die klare Definition einer Rolle bestimmt die jeweilige Expertise, die Perspektive und den Stil der Ausgabe, wodurch aufgabenspezifische Ergebnisse generiert werden (Mustafa 2024).

*Input:* Darauffolgend werden dem Modell die Informationen zur Verfügung gestellt, die es zur Erfüllung für die ihm zugewiesene Rolle benötigt. Damit wird sichergestellt, dass das LLM über das notwendige Fundament für effektive Ergebnisse verfügt (Mustafa 2024).

*Steps:* Dieses Kriterium bildet den Kern des RISE-Frameworks, in dem das LLM aufgefordert wird, einen schrittweisen und klar definierten Plan zu erstellen. Dieser Plan schließt die spezifischen Strategien ein, die für die Erreichung des gewünschten Ergebnisses erforderlich sind (Mustafa 2024).

*Expectation:* Abschließend unterstreicht das Framework die Bedeutsamkeit einer klaren Formulierung der Ergebnisse und Erwartungen. Dies gewährleistet, dass sich der Fokus des Modells auf die spezifischen Ziele konzentriert (Mustafa 2024).

### **8.5 Erforderliche Fähigkeiten für Prompt-Engineers**

Das PE wird mit zunehmender Adaption von KI-Systemen in Unternehmen als eine zentrale Qualifikation im Umgang mit diesen anerkannt (A.Shaji George/A. S.Hovan George 2023, S. 3). Aus dem Bedarf an effizienten Prompts ist mit dem PE inzwischen ein neuartiges Berufsfeld entstanden (Schneider 2023, S. 102). Durch die Steigerung der Komplexität und Leistungsfähigkeit von Sprachmodellen ist eine anhaltende Zunahme der Nachfrage nach Prompt-Engineers in allen Branchen zu erwarten (A.Shaji George/A. S.Hovan George 2023, S. 2). Allerdings existiert keine spezifische Ausbildung für das PE (Schneider 2023, S. 102). Zudem variieren, abhängig vom Industriebereich und den Verantwortlichkeiten der jeweiligen Position, die erforderlichen Kenntnisse für Prompt-Engineers stark. Jedoch lässt sich als fundamentale Fähigkeit das Wissen festhalten, präzise und für das Modell klar verständliche Eingaben zu schreiben (Sloyan 2023). In diesem Sinne bedienen sich Prompt-Engineers der Nuancen in Sprache, Logik und Emotionen sowie in der menschlichen Psychologie, um das Modell zielgerichtet zu steuern (A.Shaji George/A. S.Hovan George 2023, S. 2). Im technischen Bereich werden vermehrt Erfahrungen und Fähigkeiten ähnlich zu Software-Engineers für die Rolle als Prompt-Engineer nachgefragt. Dazu gehören z. B. Kenntnisse in den Programmiersprachen R oder Python, das Wissen über neuronale Netzwerke, Erfahrungen in der Nutzung von NLP und LLMs sowie die Entwicklung skalierbarer API-Lösungen. Dagegen konzentrieren

sich Rollen mit einem geringeren technischen Anforderungsprofil auf die Prompt-Erstellung als auf die Entwicklung neuer KI-Modelle. Hierbei wird ein Fokus auf Soft-Skills wie kreative Problemlösung, Kommunikation, Detailtreue und das jeweilige Fachwissen im geforderten Bereich gelegt (Sloyan 2023). Um einen spezifischen Blick auf die Marktforschung (Mafo) zu eröffnen, untersucht die Arbeit im Rahmen der Experteninterviews die Frage nach den erforderlichen Fähigkeiten für Prompt-Engineers. Die Ergebnisse dieser Diskussionen könnten maßgebliche Implikationen für die Ausbildung von Prompt-Engineers in diesem Fachgebiet bedeuten.

### **8.6 Kritik an Prompt-Engineering**

Zwar wird PE als Beruf mit hohem Zukunftspotenzial durch das World Economic Forum betitelt (Whiting 2023), jedoch äußern erste Stimmen ihren Skeptizismus darüber, ob PE als eine nachhaltige und gefragte Kompetenz bestehen wird (Schneider 2023, S. 104). Unter diesen Stimmen übt Oguz A. Acar im „Harvard Business Review“ Kritik an der zukünftigen Relevanz des PE; ihm zufolge verliert das PE aus verschiedenen Gründen an Bedeutung. Zunächst ließe sich absehen, dass kommende KI-Generationen geschickter und intuitiver im Verstehen natürlicher Sprache sein werden, wodurch die Notwendigkeit für sorgfältig entwickelte Prompts verringert würde. Bereits in der gegenwärtigen Zeit würden LLMs wie GPT-4 ein beträchtliches Potenzial zur Generierung von Prompts aufweisen (Acar 2023). Zudem bieten einige KI-Modelle die Anbindung von Tools, wie das „ChatGPT PROMPT Genius“, die eine Vielzahl an vordefinierten Prompts für verschiedene Themengebiete enthalten. Diese ermöglichen es dem Anwender, die Prompts, ohne tieferes Vorwissen in PE, direkt in ChatGPT auszuführen (Schneider 2023, S. 104). Weiterhin ist zu berücksichtigen, dass die Effektivität von Prompts abhängig vom jeweiligen Modell ist, weswegen ihre Nützlichkeit bei verschiedenen Modellen eingeschränkt ist. Schließlich könnte sich ein übermäßiger Fokus auf die Ermittlung der optimalen Prompt-Formulierung als kontraproduktiv erweisen, denn dies könnte das Kontrollgefühl über den kreativen Prozess schmälern sowie von der Erforschung des Problems ablenken. Somit wird PE, laut Acar, nur eine temporäre Bedeutsamkeit genießen, da es durch seinen Mangel an Übertragbarkeit, Vielseitigkeit und Nachhaltigkeit langfristig an Relevanz einbüße (Acar 2023). Diese Kritikpunkte üben sich entscheidend auf das Forschungsthema aus, indem sie die potenzielle Adaption des PE in der Marktforschung (Mafo) schmälern könnten, falls sich PE lediglich als ein gegenwärtiges Phänomen zur Interaktion mit Sprachmodellen erweist. Dementsprechend wird in den Experteninterviews Bezug auf diese Kritik

genommen, indem nach der zukünftigen Relevanz des PE in der Mafo, angesichts der Fortschritte von KI-Technologien, gefragt wird.

## 9. Methodik

Zur Beantwortung der Forschungsfrage wurden im Rahmen einer empirischen Forschung Experteninterviews geführt und die Veranstaltung des „Prompthaton“ besucht, um einen umfassenden, realitätsnahen Einblick in die Thematik des Prompt-Engineering (PE) in der Marktforschung (Mafo) zu gewinnen. Unter Berücksichtigung des vorangehenden Diskurses über die Grundlagen der Mafo und des PE und der hieraus resultierenden Forschungslücke, werden folgende Hypothesen abgeleitet, die in der weiteren Untersuchung berücksichtigt werden.

*Hypothese 1:* Die Formulierung der Prompts wirkt sich auf die Qualität der Ergebnisse aus, sodass eine präzise Gestaltung der Prompts einen entscheidenden Einfluss auf die Relevanz und Genauigkeit der Informationen besitzt.

*Hypothese 2:* Durch den Einfluss von KI-Technologien wird eine Anpassung in der Ausbildung von Marktforschern erforderlich sein, da sie spezifische Kompetenzen im Umgang mit Sprachmodellen, insbesondere im Bereich des Prompt-Engineerings, beherrschen müssen.

### Kontextuelle Auswahl von ChatGPT

Die Fokussierung dieser Arbeit auf ChatGPT als repräsentatives Large-Language-Model (LLM) gründet sich darauf, dass es mit seinem Aufkommen signifikant den Trend zur Interaktion mit KI verstärkte (Zhao u. a. 2023, S. 7) und eine treibende Kraft für Innovationen im Bereich der natürlichen Sprachverarbeitung bildet (Muneer/Maad/Hussain 2023, S. 2). Das Sprachmodell stellt eines der größten und damit leistungsstärksten und vielseitigsten generativen KI-Modelle auf dem Markt dar (Marr 2024; IBM o. J.a; Bastian 2023). Es bildet sowohl im privaten als auch im beruflichen Kontext die bei Weitem gängigste KI-Anwendung (Carbonaro 2024; Brandl 2023). In kürzester Zeit hat sich ChatGPT als ein bedeutsames Werkzeug für eine Vielzahl an Aufgaben etabliert (Sohail u. a. 2023, S. 1), wobei sich dessen Einsatzpotenzial ebenfalls auf die Mafo erstreckt (Jain u. a. 2023, S. 3). Insbesondere bewirkte die hohe Popularität ChatGPTs den dynamischen Aufstieg des PE (Mühlbauer 2023). Es ist anzunehmen, dass die Nutzung des LLMs in Zukunft steigen wird, wobei seine Fähigkeiten kontinuierlich verbessert werden (Sohail u. a. 2023, S. 2).

## 9.1 Experteninterviews

Im Rahmen der vorliegenden Arbeit stützen sich die Datenerhebung und die Überprüfung der Hypothesen auf Experteninterviews, die im Kontext der Forschungsfrage durchgeführt wurden. Sie tragen zu einem tiefergreifenden Verständnis der Thematik des PE in der Mafo bei. Diese Befragung orientierte sich an einem Leitfaden. Leitfadengestützte Experteninterviews stellen das vorherrschende Verfahren in der empirischen Sozialforschung dar und sind der Oberkategorie des Leitfadeninterviews zuzuordnen (Misoch 2015, S. 65; Kühl/Strodtholz/Taffertshofer 2009, S. 32). Trotz ihrer zielgerichteten Durchführung zeichnen sie sich durch ihre Möglichkeit des offenen Fragens aus (Kühl/Strodtholz/Taffertshofer 2009, S. 33). Leitfadeninterviews zählen zu den „semi-strukturierten Erhebungsformen zur Ermittlung verbaler Daten“ (Misoch 2015, S. 65). Als solche sind jegliche Verfahren der qualitativen Datenerhebung zu benennen, die sich eines im Voraus formulierten Leitfadens bedienen (Misoch 2015, S. 65). Experteninterviews werden eingesetzt, um „komplexe Wissensbestände zu rekonstruieren, die für die Erklärung sozialer Phänomene, auf die sich das aktuelle Forschungsinteresse bezieht, von Bedeutung sind“ (Kühl/Strodtholz/Taffertshofer 2009, S. 35). Zudem eignen sie sich zur „Exploration des Unbekannten“ (Kühl/Strodtholz/Taffertshofer 2009, S. 36) sowie zur „Rekonstruktion subjektiver Deutungen und Interpretationen“ (Bogner/Littig/Menz 2014, S. 2). Unter Experten werden im Wesentlichen Personen verstanden, die über ein spezifisches Wissen verfügen (Kühl/Strodtholz/Taffertshofer 2009, S. 33). Somit sind Experteninterviews dadurch gekennzeichnet, dass sie auf eine selektierte Gruppe von Personen abzielen, die spezifische Fachkenntnisse im Kontext des Forschungsinteresses besitzen (Kühl/Strodtholz/Taffertshofer 2009, S. 33).

### Methodik der Interviews

Zur Realisierung der Interviews wurden sachkundige Personen ausgewählt, die in den für das Forschungsthema relevanten Bereichen tätig sind, darunter KI, Sprachmodelle, ChatGPT, PE und Mafo. Insgesamt wurden im Zeitraum vom 8. Februar bis zum 8. April 2024 neun Experteninterviews geführt, die online via Zoom stattfanden. Die Interviews wurden unter Einverständnis aufgezeichnet und transkribiert. Der Leitfaden sowie die Transkripte der jeweiligen Experteninterviews sind in den Anhängen 15 und 17 bis 25 aufgeführt. Zudem finden sich weitere Erkenntnisse in Anhang 16, die die Diskussion um das Thema KI und PE in der Mafo bereichern. Das zentrale Element qualitativer Interviews bildet der Leitfaden, der eine Strukturierungs- und inhaltliche Steuerungsfunktion innehat. Damit dient der Leitfaden als roter Faden zur Erhebung der verbalen, qualitativen Daten und stellt gleichzeitig deren Vergleich-

barkeit sicher. Die Fragen sind trotz thematischer Rahmung möglichst offen zu formulieren, sodass die Experten in der Lage sind, frei zu antworten und von ihren eigenen Erfahrungen und Gefühlen zu sprechen. Dadurch wird genügend Raum für neue Erkenntnisse und spontane Antworten gewährleistet (Misoch 2015, S. 65–66). Experteninterviews stellen den Anspruch, verschiedene Perspektiven auf das Forschungsthema zu gewinnen, die mit jedem weiteren Interview expandieren. Sie finden allerdings nur so lange statt, bis keine neuen Erkenntnisse mehr auftreten, d. h. eine „theoretische Sättigung“ (Bogner/Littig/Menz 2014, S. 36) erreicht wurde.

## 9.2 Prompthon

Im Zuge der empirischen Untersuchung wurde die Möglichkeit wahrgenommen, die Veranstaltung „*Promptathon: Businessplan mit ChatGPT*“ zu besuchen, um einen praktischen Einblick in den Bereich des PE zu gewinnen. Zudem wird eine erweiterte Perspektive auf die industrieweite Herausforderung der sachgemäßen Handhabung von KI, im Speziellen ChatGPT, eröffnet. Der Prompthon stellt einen Workshop des Digitalisierungszentrums Ulm, Alb-Donau, Biberach, Neu-Ulm in Kooperation mit dem ITZ Plus Biberach dar und dient dem Aufbau von grundlegenden Kenntnissen im Umgang mit ChatGPT und Prompting. Der Prompthon fand am 7. März 2024 im ITZ Plus Biberach statt und umfasste 20 Teilnehmer aus verschiedenen Industriebereichen sowie zwei präsentierenden Experten im Bereich KI und PE. Ein ausführlicher ethnographischer Bericht des Prompthon kann dem Anhang 14 entnommen werden.

## 10. Ergebnisse der Forschung

Im Folgenden werden die Ergebnisse aus den Experteninterviews und dem Prompthon ausgewertet und zusammengefasst aufgeführt. Zur Orientierung dient die Reihenfolge der Fragen im Leitfaden. Die Experten sind im Sinne einer Zuordnung der einzelnen Aussagen nach der Reihenfolge nummeriert, in der die Interviews stattfanden und werden kurz vorgestellt.

*Experte 1:* Professor mit Schwerpunkt auf Anwendungen der KI, insbesondere im Bereich NLP und KI-gestützte Chatbots.

*Experte 2:* Professor für Digitale Transformation und Entrepreneurship.

*Expertin 3:* Beschäftigt sich im Rahmen ihrer Forschung mit Themen aus dem Technologie- und Innovationsmanagement.

*Experte 4:* Gründer und Geschäftsführer eines KI-Beratungsunternehmens, das Unternehmen im Marketing und in der Mafo bei der Implementierung von KI, ChatGPT und PE unterstützt.

*Experte 5:* Berater für Business-Model-Innovation, Design-Thinking und agile Transformation mit Schwerpunkt auf KI und PE.

*Experte 6:* Der Fokus seiner Forschung liegt im Training und der Verwendung von LLMs.

*Experte 7:* Berater, dessen Schwerpunkte in der Anwendung von Machine-Learning (ML) zur Ermöglichung neuer Geschäftsmodelle sowie im Einsatz von generativer KI und PE im Geschäftskontext liegen.

*Experte 8:* Gründer und Geschäftsführer eines Mafo-Unternehmens, in dem er sich mit den innovativen Ansätzen der KI und deren Einsatzmöglichkeiten in der Mafo befasst.

*Expertin 9:* Inhaberin und Managing Partner eines Mafo-Unternehmens. Sie stellt eine Expertin für KI-gestützte Marketinginnovationen mithilfe von PE dar.

## **Auswertung der Ergebnisse**

### ***Welche Rolle nimmt Prompt-Engineering in der Marktforschung ein?***

Es herrscht ein mehrheitlicher Konsens, dass Prompt-Engineering (PE) eine bedeutende Rolle bei der Nutzung von Sprachmodellen wie ChatGPT in der Marktforschung (Mafo) einnimmt.<sup>2</sup> Die Experten 1 und 4 betonen, dass PE erst durch die Veröffentlichung von ChatGPT in den Fokus der Diskussion getreten ist. Laut Experte 7 begründet sich die Relevanz des PE darin, dass es die Art und Weise darstellt, wie mit den Modellen zu interagieren ist. Experte 2 und Expertin 3 sehen PE als Voraussetzung an, um die gewünschten Ergebnisse in benötigter Qualität erzielen zu können. Effizientes Prompting zeichne sich durch eine Instruktion ChatGPTs aus, die Informationsbeschaffung in einem ausführlichen Detailgrad bereitzustellen (3). Hierbei sei ein Analysegeschick für „gute und schlechte Antworten“ gefragt (3, siehe Anhang 19). Expertin 9 hebt hervor, dass Mafo und PE eine theoretische Schnittmenge darin aufweisen, dass der richtigen Fragestellung eine höhere Gewichtung zugemessen wird, um das gewünschte Ziel zu erreichen. Aus Sicht der Expertin 9 besteht in der Praxis allerdings ein Defizit in der analytischen Abstraktionsfähigkeit, d. h. die richtigen Fragen an das Modell stellen zu können. Ferner merkt Experte 4 an, dass viele Forscher eine Wissenslücke für die ersten Schritte im Umgang mit ChatGPT aufweisen, nämlich dahingehend wie das Modell im Sinne

---

<sup>2</sup> Experten 2, 3, 4, 7, 8 und 9.

von PE korrekt zu bedienen ist. Dementsprechend sei es maßgeblich, sich intern das erforderliche Know-How anzueignen, um adäquate Prompts schreiben sowie diese sukzessive entwickeln zu können (4). Zwar sieht Experte 8 eine gewisse Relevanz des PE für die Mafo, jedoch will er dessen Gewichtung nicht überbewerten, vielmehr müsse sich erst beweisen, wie bedeutend PE werde. Experte 8 berichtet, dass mit dem Aufkommen von PE vielfach diskutiert wurde, ob sich dahingehend ganze Berufszweige bilden werden, wobei er einräumt, dass es Menschen gibt, die sich auf PE spezialisieren. In der Praxis nimmt Experte 8 jedoch an, dass nicht jeder Forscher seine eigenen Prompts schreiben müsse, sondern sich an einer vordefinierten Prompt-Sammlung bedient. Hierbei seien weiterhin Prompt-Engineers erforderlich, die dafür zielgerichtete Prompts schreiben können, die in einem iterativen Verfahren optimiert und festgesetzt werden. Damit solle die Wiederholbarkeit der Ergebnisse sichergestellt werden (8).

***Gehen Sie davon aus, dass die Fähigkeit des Prompt-Engineerings zu einer weiteren Kompetenz für Marktforscher wird, wenn diese mit ChatGPT zusammenarbeiten möchten?***

Zwar sind die Experten davon überzeugt, dass PE eine entscheidende Fähigkeit für die effektive Nutzung von Sprachmodellen darstellt, jedoch divergieren die Meinungen in Bezug darauf, wie umfassend PE als Kompetenz in der Mafo zu verankern ist. Die Experten 2, 4, 5 und 7 sehen für den Einsatz von Sprachmodellen in der Mafo die Notwendigkeit, PE zu erlernen, um bessere Ergebnisse erzielen zu können. Eine Relevanz des PE bestünde nicht nur in der Mafo, sondern in jedem Bereich, in dem Sprachmodelle oder generative KI eingesetzt würden (4, 5). Experte 8 ist sich jedoch unschlüssig, ob PE als eigenständige Kompetenz in der Mafo etabliert werden sollte. Seines Erachtens ist PE eine vorteilhafte Kompetenz, die jedoch nicht jeder Marktforscher zwingend benötigt. Zudem sei PE für unkomplizierte Aufgaben überflüssig. Sowohl Experte 8 als auch Experte 7 machen die Anzahl der benötigten Prompt-Engineers und den Grad deren Spezialisierung von der Unternehmensgröße abhängig. Für Experte 7 und Expertin 9 erscheint es wahrscheinlich, dass sich hybride Modelle festigen werden. Einerseits existieren Forscher, die vordefinierte GPT-Modelle und Prompt-Templates bereitgestellt bekämen, sodass keine umfassenden PE-Kenntnisse erforderlich seien (7, 9). Zudem könne nicht jeder Forscher das für PE benötigte Abstraktionsvermögen vorweisen (9). Andererseits würden PE-Spezialisten benötigt, die diese GPTs und umfangreichen Prompts entwickeln können (7, 9). Laut Experte 7 ist PE unverzichtbar, um Modelle so aufzusetzen, dass eine breite Masse sie bedienen kann. Dagegen sehen Experte 1 und Expertin 3 das PE nicht als eine zentrale Kompetenz für die Mafo. Beide Experten sind vielmehr der Meinung,

dass PE zu Allgemeinwissen wird, das mit der Fähigkeit zur Datenbankrecherche zu vergleichen ist (3). Mit Blick auf GPT-Agents und Assistants, wird das PE laut Experte 1 in den Hintergrund rücken, sodass dessen Bedeutsamkeit laut seiner Prognose abnehmen wird und es keine Fähigkeit ist, die aus der Masse heraussticht. Gemäß Expertin 3 ist PE lediglich als ergänzende Fähigkeit zu den Kompetenzen der Mafo zu sehen, sodass es keine wettbewerbsdifferenzierende Fähigkeit darstellt.

***Nehmen Sie an, dass Prompt-Engineering unerlässlich für Marktforschungsunternehmen ist, die Sprachmodelle wie ChatGPT nutzen wollen?***

Die Mehrheit der Experten teilt die Ansicht, dass PE erforderlich ist, um ChatGPT im Geschäftskontext effizient zu nutzen.<sup>3</sup> Mit PE könnten deutlich bessere Ergebnisse erreicht werden, wobei die Qualität der Ergebnisse von der Qualität der Prompts abhängig sei (4, 5, 9). Dementsprechend seien ungünstige Ergebnisse nicht auf das Modell zurückzuführen, sondern auf eine mangelnde Qualität der Fragen. Das PE würde es erlauben, bisher unzugängliche Ziele zu erreichen (9). Gemäß Experte 2 ist es ratsam, für geschäftskritische Anwendungen eine sorgfältige Überlegung der Prompt-Formulierung durchzuführen. Er unterstreicht, dass die Art und Weise, wie elaboriert Prompts formuliert sind, einen entscheidenden Einfluss auf die Ergebnisse ausübt. Hierbei sollten verschiedene PE-Techniken Beachtung finden, um das Modell zur Ausgabe relevanter Ergebnisse zu steuern. Dabei bemängeln Experte 4, 5 sowie 9, dass vielen Menschen nicht nur das Grundverständnis für geschicktes Prompting fehlt, sondern ebenfalls das begleitende Wissen, z. B. was unter Kontext oder Knowledge zu verstehen ist und welche realistischen Möglichkeiten die KI bietet. Demnach würde ein effizienter Prompt allein nicht genügen, um optimale Ergebnisse erzielen zu können (5). Für Experte 4 ist es essenziell, Forschende dementsprechend fortzubilden. Experte 8 ist dagegen unsicher, in welchem Ausmaß PE gebraucht wird, und wie viele Forscher insoweit beansprucht werden.

***Welche Vorteile bestehen darin, Prompt-Engineering in der Marktforschung einzusetzen, wenn mit einer KI wie ChatGPT zusammengearbeitet wird?***

Laut den Experten lassen sich zahlreiche Vorteile durch die Anwendung von PE beobachten. Für Experte 2 stellt PE grundsätzlich die Vorstufe dar, wie die KI zu bedienen ist. Ihm zufolge hängt die Generierung präziser und relevanter Ergebnisse von der Konkretisierung der Prompts ab, weshalb konkretere Anfragen zu zielgerichteteren Ausgaben führen würden. Die Experten 4, 5 und 7 heben hervor, dass PE zu schnelleren und qualitativ hochwertigeren Er-

---

<sup>3</sup> Experten 2, 4, 5, 6, 8 und 9.



gebnissen verhilft. Gleichzeitig könnte hierdurch die mit ineffizientem Prompting verbundene Frustration vermieden werden (4). Mit PE könnte eine Steigerung der Effektivität und Effizienz erreicht werden, wobei die Effektivität das erwünschte Ergebnis in hoher Qualität und Effizienz die Prozessbeschleunigung und Robustheit der Ergebnisse bezeichne (7). Unter Robustheit oder Stabilität sei die Wiederholbarkeit der Ergebnisse zu verstehen, was ein entscheidendes Kriterium für die Mafo sei, die zuverlässige und konsistente Ergebnisse erfordere. Dies würde eine Herausforderung für den Einsatz von Sprachmodellen darstellen, da LLMs nicht deterministisch seien (7). Gemäß den Experten 7 und 8 kann mit PE sichergestellt werden, dass die Ergebnisse ein höheres Maß an Stabilität und Reliabilität aufweisen. Laut Experte 8 wird der Prompt in einem iterativen Prozess so weit optimiert, bis die benötigte Stabilität erzielt wird. Dieser Prompt würde nicht weiter modifiziert und sei für alle Mitarbeiter zugreifbar, sodass eine Standardisierung gewährleistet sei. Des Weiteren kann sich PE laut Experte 4 als nützlich erweisen, um die potenzielle Gefahr von Halluzinationen und Biases in den Ausgaben des Modells zu reduzieren. Jedoch betont er, dass eine Fachexpertise wesentlich ist, um die Antworten der KI einschätzen zu können.

***Inwieweit wirkt sich die Formulierung der Prompts auf die Qualität der Ergebnisse aus?***

Laut den Experten und dem Prompthaton übt die Formulierung der Prompts einen entscheidenden Einfluss auf die Qualität der Ergebnisse aus. Schlechte Ergebnisse seien in der Regel auf schlechte Prompts zurückzuführen. Dementsprechend sei PE für die Gewährleistung hochwertiger Ergebnisse entscheidend.<sup>4</sup> Ohne die Fähigkeit des PE, würden nicht die erhofften Ergebnisse in benötigter Qualität erreicht (2). Bezüglich der Einflussnahme auf die Qualität ist für Experte 7 ein kritischer Faktor, den Freiheitsgrad des Modells durch PE zu steuern. Ihm zufolge sind LLMs autoregressive Modelle, d. h. sie sagen das nächste Wort auf Basis des vorherigen Wortes voraus. Ohne eine Steuerung würden die Relevanz und die Qualität der Ausgaben von der Erwartungshaltung des Nutzers fortschreitend divergieren. Dementsprechend sei es ratsam, mithilfe von PE die Richtung des Modells zu korrigieren, um die Ergebnisqualität und die Erwartung des Nutzers in Einklang bringen zu können. Zudem unterstreicht Experte 7 die Empfindlichkeit von LLMs gegenüber Schlüsselwörtern und infolgedessen die Möglichkeit, dass diese die Ergebnisse unbeabsichtigt beeinflussen könnten, sodass die Notwendigkeit einer sorgfältigen Prompt-Formulierung besteht.

---

<sup>4</sup> Experten 1, 2, 3, 5 und 9 sowie Prompthaton.

***Was ist bei der Formulierung eines zielgerichteten Prompts zu beachten?***

Die Experte 1 und 4 heben hervor, dass Prompts mit einem gewissen Grad an Strukturierung eine höhere Wahrscheinlichkeit aufweisen, bessere Ergebnisse zu liefern. Experte 1 bezeichnet diese als Prompting-Frameworks, wobei es maßgeblich sei, diese auf die spezifischen Anforderungen zuzuschneiden. Grundsätzlich ist laut Experte 4 zu priorisieren, das Problem klar zu erkennen und zu verstehen, um es präzise und verständlich für das Modell formulieren zu können. Bei den Bestandteilen eines strukturierten Prompts stimmen die Mehrheit der Experten (mit Ausnahme des Experten 6) und der Prompthaton zu einem Großteil überein. Es sei essenziell, zunächst das Thema der Aufgabenstellung sowie das Ziel klar zu definieren.<sup>5</sup> Durch diese Spezifikation erhalte ChatGPT eine Orientierung, in welche Richtung es sich bewegen solle (4). Gemäß Expertin 9 ist das Verständnis des Ziels das signifikanteste Kriterium für die Entwicklung des Prompts. Sie betont, dass es für das Prompting keinen „One-Size-fits-All-Approach“ gäbe (siehe Anhang 25), da sich die Determinanten des Prompts aus der jeweiligen Zielstellung ergäben. Der Prompthaton plädiert ebenfalls dafür, abhängig vom Anwendungsfall mit den Prompt-Techniken zu experimentieren. Des Weiteren sei es empfehlenswert, dem Modell eine Rolle und seine Kompetenzen zuzuteilen<sup>6</sup> und die Zielgruppe zu beschreiben, an die sich die Ergebnisse richten.<sup>7</sup> Experte 7 merkt an, dass ChatGPT, abhängig von der Zielgruppe, eine andere Wortwahl in seinen Antworten nutzen müsse. Es empfehle sich hierbei die Wortanzahl sowie den Schreibstil festzulegen (2, 8). Zudem sei eine erfolgsversprechende Praxis, das Modell mit relevantem Kontext anzureichern (4, 5, 7, Prompthaton). Gemäß Experte 5 sei je nach Anwendungsfall zu fragen, welcher und wie viel Kontext zur Verfügung zu stellen ist, wobei ihm zufolge die Ergebnisse umso relevanter werden, je mehr Kontext bereitgestellt würde. Neben dem Kontext sei es im Bereich der Marktforschung (Mafo) ebenfalls sinnvoll, das entsprechende Knowledge im Prompt beizufügen (5). So können laut Experte 5 bei der Generierung eines Fragebogens Dokumente mit ähnlichen Umfragen zur Orientierung bereitgestellt werden. Darüber hinaus könne das Ergebnisformat im Prompt bestimmt werden<sup>8</sup>, z. B., ob eine Präsentation erstellt werden sollte sowie die Arbeitsschritte, die zu diesem Ergebnis führen würden, zu definieren (5, 7, Prompthaton). Hierbei sei es nach Experte 7 entscheidend, Richtlinien im Prompt festzulegen, insbesondere in der Kreativarbeit. Die Experten 4 und 7 sowie der Prompthaton empfehlen ferner, ChatGPT Rückfragen stellen zu lassen,

<sup>5</sup> Experten 1, 3, 4, 5, 7 und 9 sowie Prompthaton.

<sup>6</sup> Experten 1, 2, 3, 4, 5, 7, 8 und 9 sowie Prompthaton.

<sup>7</sup> Experten 1, 4, 5, 7 und 8 sowie Prompthaton.

<sup>8</sup> Experten 1, 3, 5 und 7 sowie Prompthaton.

bevor das Modell mit einer Aufgabe beginnt, damit eventuelle Unklarheiten verhindert und das Modell feiner auf das Problem abgestimmt werden könnten. Neben der direkten Formulierung des Prompts, ist es für Experte 7 ein kritischer Aspekt, die Parameter des LLM abhängig von der Problemstellung zu definieren, um zuverlässige Ergebnisse zu erhalten. Diese seien nicht in ChatGPT variierbar, sondern würden sich auf der API-Plattform festlegen lassen (1). Gemäß Experte 7 ist der relevanteste Parameter die Temperatureinstellung, die bestimme, wie deterministisch oder variabel die KI in ihren Ausgaben sein dürfe. Sei das Problem klar definiert und es existiere nur eine richtige Lösung, sollte die Temperatur deterministisch eingestellt werden, sodass bei Wiederholung das gleiche Ergebnis zu erwarten wäre. Sollte das Modell dagegen einen Text generieren, sei eine höhere Variabilität in seinen Ausgaben erlaubt (7).

***Wie kann die Nutzung von Prompt-Engineering die Genauigkeit und die Effizienz von Marktforschungsstudien optimieren?***

Experte 1 betont die Fähigkeit des PE, Qualitätsstandards, für die von ChatGPT genutzten Quellen, festzulegen. Das Modell könne angeleitet werden, ausschließlich bestimmte Wissensdatenbanken oder Archive als Quellen zu verwenden. Die Spezifizierung der Quellenauswahl wirke sich erheblich auf die Genauigkeit und Relevanz der Ergebnisse aus. Zudem könnten Anforderungen an die Qualität der Ergebnisse durch PE gestellt werden. Beispielsweise könne eine Quellenüberprüfung durch Bereitstellung von Links und Website-Aufrufen durchgeführt werden, wobei unzuverlässige Quellen als fehlerhaft zu markieren seien. Dies könne dazu beitragen, Halluzinationen auf ein Minimum zu beschränken (1). Experte 8 vertritt eine gemäßigte Sichtweise, indem er einräumt, dass mit dem momentanen Stand der Anwendung von ChatGPT und PE lediglich einige unkomplizierte Tätigkeiten automatisiert und damit geringfügig schneller und kostengünstiger bearbeitet werden könnten. Grundsätzlich betrachtet Experte 8 es zum aktuellen Zeitpunkt kritisch, die Auswirkungen des Sprachmodells auf eine signifikante Verbesserung der Marktforschung (Mafo) überzubewerten. Nichtsdestotrotz seien Mafo-Unternehmen zur Reflexion angehalten, welche Aufgabenfelder für eine Automatisierung in Betracht gezogen werden könnten und wie das entsprechende Prompting hierfür zu entwickeln sei. Laut Experte 8 ist, trotz PE, weiterhin menschliches Eingreifen unerlässlich, um die Ergebnisse im Fall von Halluzinationen korrigieren zu können. Für Expertin 9 besteht der Nutzen des PE insbesondere in der Gewährleistung, die generierten Ergebnisse spezifisch an Kunden und Zielgruppen anpassen zu können. Das Sprach-

modell könne angeleitet werden, verschiedene Persönlichkeitstypen präzise anzusprechen und zu erklären, weshalb die jeweilige Formulierung gewählt wurde (9).

***Für welche spezifischen Anwendungsgebiete ist das Prompt-Engineering in der Marktforschung besonders geeignet?***

Gemäß Experte 1 ist PE universell in der Mafo anwendbar. Hierbei verweist er auf die Möglichkeit, erhebliche zeitliche Ressourcen einsparen zu können, indem schneller bessere Ergebnisse erreicht werden können, bei Tätigkeiten, die ohne KI-Einsatz sehr arbeitsintensiv wären. Demzufolge ist laut Experte 1 der gesamte Wertschöpfungsstrom, ohne KI wirtschaftlich nicht leistbar. Die Experten 2, 3, 5, 7 und 9 sehen das Einsatzpotenzial von PE und ChatGPT insbesondere im qualitativen Bereich der Mafo, wobei sie (mit Ausnahme von Expertin 9) die Möglichkeit zur verbesserten Erstellung von Fragebögen unterstreichen. Indem die zuvor ausgeführten Methoden für eine zielgerichtete Prompt-Formulierung beachtet würden, wie die präzise Beschreibung der Zielstellung und der Zielgruppe, könnten die Fragebögen präzise auf den Forschungsfokus zugeschnitten werden (2). Laut Experte 5 ist PE zudem für die Entfernung möglicher Biases aus Fragebögen nützlich. Er führt aus, dass bei der händischen Entwicklung von Fragebögen Biases des Forschers in Form des persönlichen Schreibstils entstehen könnten. Indem Fragebögen mithilfe von PE spezifiziert würden, könnten Biases verhindert und eine zielgruppengerechtere Formulierung erreicht werden (5). Gemäß Expertin 9 kann PE zudem für einen ersten generativen Einsatz der KI genutzt werden, um Einblicke in Kundenbedürfnisse zu gewinnen. Hierbei könne die KI zu einer Expertenmeinung bezüglich der Kriterien „Pains, Gains, Motivation, Barrieren, Needs, Value-Propositions und Benefit-Letters“ gefragt werden (siehe Anhang 25). Experte 8 zufolge ist das PE in denjenigen Anwendungsgebieten relevant, in denen das Mafo-Unternehmen eine Standardisierung erreichen will, wobei PE zentral ist, um die KI-gestützten Aufgaben in den Arbeitsprozess einzubetten. Experte 8 und Expertin 9 sehen eine weitere bedeutsame Aufgabe des PE darin, personalisierte Anwendungen in ChatGPT entwickeln zu können, etwa einen Research-Assistent, der als Wissensdatenbank dient. Hierzu müssten im GPT-Modell spezifische Prompts hinterlegt werden, die das Verhalten der KI steuern. Somit sei die Anwendung von PE sinnvoll, wenn ein Vorgang fest im Mafo-Unternehmen etabliert werden solle und die Forscher vordefinierte Prompts nutzen sollten (8). Die Standardisierung reduziere zudem die Fehleranfälligkeit der Prompts (8).

***Welche Prompt-Engineering-Strategien sind für die Marktforschung besonders relevant?***

Gemäß den Experten 3, 7 und 9 gibt es keine einheitlich gültige Prompting-Strategie. Vielmehr sei PE als ein vielseitiges Werkzeug zu sehen, wobei die konkrete Auswahl einer Strategie passend zum jeweiligen Anwendungsfall erfolgen sollte. Allerdings würden Experte 7 sowie Expertin 3 davon abraten, sich nach externen Strategien zu richten und plädieren für eine Selbstexploration der Nutzung von PE-Strategien. Nichtsdestotrotz gäbe es grundlegende Methodiken, die bei der Interaktion mit ChatGPT ratsam erscheinen (3). Als eine elementare Strategie würde Experte 7 empfehlen, die jeweilige Problemstellung in der Marktforschung (Mafo) spezifisch im Prompt zu erläutern und sich durch ChatGPT unterstützen zu lassen, die richtigen Fragen zu entwickeln sowie ausreichend Kontext über das Problem zu sammeln. Dies sei der erste und zentrale Schritt, denn die KI könne nur einen sinnvollen Beitrag leisten, wenn sie das Problem und Forschungsziel klar verstehe (7). Eine weitere grundsätzliche Strategie sei es, ein aktives und zielgerichtetes Wechselwirken mit ChatGPT anzustreben (3, 4). Je präziser der Dialog mit ChatGPT geführt würde, desto adäquater seien die Ergebnisse, weshalb allgemeine Anfragen in der Regel zu vermeiden seien (3). Zudem ist laut Expertin 3 eine wirksame Strategie, Rückfragen an ChatGPT zu stellen, falls sein Lösungsweg unnachvollziehbar erscheint, was den gegenseitigen Austausch bestärke. Weiterhin wird die Zuteilung einer Rolle von Experte 4 und 5 als eine generell erfolgversprechende Strategie empfohlen. Laut Experte 5 kann es zudem sinnvoll sein, die Rollen zu tauschen und damit die Strategie umzukehren. Demnach würde die KI nicht nur mit Input angereichert, sondern aktiv abgefragt, ob sie über die notwendigen Ressourcen zur Ausführung der Aufgabe verfügt, ob Wissenslücken bestehen und ob sie weitere Fragen hat. Diese Strategie eignet sich laut Experte 5 besonders für explorative Aufgaben. Außerdem sei es ratsam, ChatGPT anzuleiten, nach einem strukturierten Prozess vorzugehen und die einzelnen Schritte iterativ durchzuführen (4, 5). Dies könne die Forscher insbesondere bei deskriptiven Aufgaben unterstützen, zu einem bestimmten Ergebnis zu gelangen (5). Experte 6 empfiehlt zudem das Chain-of-Thought-Prompting (CoT) als eine weitere Strategie, die in der Regel zu zuverlässigen Ergebnissen führe. Das CoT könne die KI effektiv anweisen, ihre Antworten sowie den schrittweisen Vorgang zu erläutern, durch den sie ihre Antworten generiert. Des Weiteren rät Experte 1 zur Beachtung der verschiedenen Shot-Prompting-Arten, etwa Zero-Shot (0S) oder Few-Shot (FS), die zu besseren Ergebnissen führen.

***Über welche spezifischen Fähigkeiten sollten Marktforscher verfügen, um das volle Potenzial von Prompt-Engineering auszuschöpfen?***

Gemäß den Experten 2, 4, 8 und dem Prompthaton ist es als eine Grundvoraussetzung zu sehen, diesem Thema mit Offenheit und Neugierde zu begegnen, um mit Prompt-Engineering-Techniken (PE) experimentieren zu können. Hierbei unterstreicht Experte 2 die Fähigkeiten, kreative Lösungsansätze zu entwickeln sowie Durchhaltevermögen bei der Optimierung von Prompts zu beweisen. Die Experten heben zudem hervor, dass Forscher für die Anwendung von PE eine gewisse Abstraktionsfähigkeit und ein Analysegeschick dahingehend besitzen müssen, wie sie die Aufgabenstellung in einem strukturierten Prozess für die KI verständlich formulieren und zum gewünschten Ergebnis gelangen könnten (2, 4, 8, 9). Expertin 9 und der Prompthaton betonen, dass ein zielgerichteter Blick auf die Ergebnisse von essenzieller Bedeutung ist. Am relevantesten sei hierbei die eigene Fachkompetenz, um die Lücke zwischen dem gewünschten Ziel und dem, was die KI für dessen Erreichung braucht, schließen zu können. Laut Expertin 9 ist die Marktforschung (Mafo) in der Theorie für eine Kompetenzentwicklung in den Gebieten der KI und des PE prädestiniert, da bereits eine Sensibilisierung für ethische und datenschutzrechtliche Aspekte sowie ein Augenmerk auf Korrelationen zwischen den Daten bestünden. Dementsprechend gäbe es hohe Schnittmengen zwischen den Denkweisen und Methoden der Mafo und des PE, die für die Erstellung von effizienten Prompts essenziell seien. Praktisch gesehen spreche Expertin 9 aus Erfahrung, dass die dafür vorauszusetzende Zielgerichtetheit sowie die Abstraktions- und Antizipationsfähigkeit nicht im erforderlichen Maße in der Mafo verbreitet seien. Folglich seien Marktforscher nicht automatisch gute Prompt-Writer und sollten grundsätzlich eine höhere Kompetenz in diesen Fähigkeiten erwerben (9). Zur Frage, ob Prompt-Engineers in der Mafo ein tiefgreifendes Verständnis über KI und ChatGPT benötigen, entgegnet die Mehrheit der Experten<sup>9</sup> sowie der Prompthaton, dass dies nicht zwingend notwendig ist, um effizientes PE zu beherrschen und für einen Großteil der Aufgaben nicht erforderlich ist. Außerdem ist das PE laut Experte 6 ein neues und sich im Wandel befindliches Fachgebiet, in dem das Lernen durch praktisches Experimentieren und Erfahrungssammlung erfolgt. Dennoch sei zumindest ein grundlegendes Verständnis von ChatGPT unerlässlich, insbesondere in der Mafo, die sich mit großen Daten- und Textmengen beschäftige, wobei LLMs ein hohes Potenzial zur Arbeitsauflastung bergen (4). Dementsprechend sei es ratsam, die generellen Eigenheiten des Modells, ihre Funktionalitäten und Einsatzmöglichkeiten sowie ihre Grenzen zu kennen, um sie zielgerichtet bedienen zu können (1,

<sup>9</sup> Experten 1, 2, 4, 5, 6, 7 und 8.

2, 4, 9, Prompthaton). Beispielsweise sei es entscheidend, zu wissen, dass LLMs zu Halluzinationen neigen, wodurch die Ergebnisse stets verifiziert werden müssten (2, Prompthaton). Experte 5 unterscheidet in diesem Kontext verschiedene Kategorien von Prompt-Engineers mit variierendem Kenntnisstand, von praktischen Nutzern bis zu Experten mit detailliertem Fachwissen. Letztere würden Programmierungsfähigkeiten sowie ein umfangreiches Verständnis für die Mechanismen der KI aufweisen. Experte 5 ist allerdings der Ansicht, dass sich ein guter Prompt-Engineer nicht das Niveau eines Experten erreichen muss, um solide Ergebnisse erreichen zu können. Experte 8 merkt hierzu an, dass erweiterte IT-Kenntnisse, wie Programmierfähigkeiten, neben PE-Kenntnissen benötigt werden, wenn KI-gestützte Aufgaben und Abläufe fest im Mafo-Unternehmen implementiert werden. Hierbei sei das technische Verständnis von Vorteil, um Schnittstellen wie die API von OpenAI bedienen zu können. Jedoch ist es für Experte 8 und Expertin 9 keine zwingende Voraussetzung, dass Prompt-Engineers in der Mafo erweiterte Programmierkenntnisse aufweisen, vielmehr sollen sie über ein umfangreiches Wissen im Projektgeschäft verfügen. Einen Bedarf hinsichtlich fortgeschrittener Kenntnisse im PE sieht Experte 4 bei der Beeinflussung der LLM-Parameter, beispielsweise um die Variabilität der Ausgaben für starre Aufgaben mithilfe der Temperatureinstellung zu begrenzen.

***In welchem Grad könnte der Einsatz von Künstlicher Intelligenz und insbesondere Prompt-Engineering als neue Kompetenz die bisherigen Forschungsansätze und -methoden in der Marktforschung verändern?***

Laut Experte 2 bewirkt die Anwendung von PE eine Veränderung in dem Maße, dass die Entwicklung von Prompts eine kreativere und lösungsorientiertere Denkweise sowie Experimentierfreudigkeit erfordert. Zudem sei es bedeutsam, eine kritische Bewertung der generierten Ergebnisse zu implementieren und die Prompts entsprechend zu modifizieren. Dadurch würde der Forschungsprozess insgesamt iterativer, da die Optimierung von Prompts einige Testdurchläufe beanspruche (2). Die Experten 7 und 8 bewerten es jedoch kritisch, ob PE einen disruptiven Einfluss auf die Forschungsmethoden ausübt. Zwar erkennen sie das disruptive Potenzial von KI und PE an, allerdings stellt laut Experte 7 die Informationsasymmetrie in Unternehmen eine nicht zu unterschätzende Herausforderung dar. Diese bremse die transformativen Auswirkungen von KI in der Mafo und limitiere den Einsatz von PE erheblich (7). Hierbei würde der Erfolg der Integration von KI und PE im Wesentlichen von der Qualität und Verfügbarkeit der Daten abhängen. Mafo-Unternehmen, die keine robuste Dateninfrastruktur aufweisen, seien nicht in der Lage, die KI gewinnbringend einzusetzen und würden

aus dem Markt ausscheiden (7). Einen transformativen Charakter sieht Experte 7 im Rahmen der Ausführung einzelner Aufgaben, etwa bei der Erstellung und Auswertung von Fragebögen. Experte 8 berichtet aus seinem Mafo-Unternehmen, dass PE und ChatGPT derzeit für Aufgabenbereiche angewendet werden, die nur begrenzt disruptiv sind und vorwiegend der Reduzierung des Kosten- und Zeitfaktors dienen. Der Experte hebt hervor, dass der KI-Bereich zwar einen enormen Qualitätssprung durch die Entwicklung von ChatGPT erfahren habe, jedoch die Bedienung von Schnittstellen zur Datenanalyse weiterhin eine Herausforderung darstelle, da ChatGPT kein mathematisches Modell sei. Somit schließt Experte 8, dass die Auswirkungen auf die Forschungsmethoden durch PE, aufgrund des gegenwärtig limitierten Einsatzes von Sprachmodellen, einen überschaubaren Umfang haben.

***In welcher Weise könnten Marktforscher zukünftig geschult werden, um effektiv mit Künstlicher Intelligenz und Prompt-Engineering umgehen zu können?***

Experte 1 betont, dass eine Transformation in der Ausbildung von Marktforschern nicht nur eine Frage des Prompt-Engineering (PE) ist, sondern sich aus der Expansion der KI insgesamt begründe. Ihm zufolge ist es ein fataler Wettbewerbsnachteil, nicht die KI im Forschungsprozess einzusetzen und die entsprechenden Kompetenzen auszubilden. Hierbei sei PE als eine „Facette der Ausbildung“ zu verstehen (siehe Anhang 17). Zudem hebt Experte 1 hervor, dass Marktforscher zunächst ein explizites Verständnis über den Forschungsprozess aufweisen müssen, um bewerten zu können, welche Kompetenzen in den verschiedenen Phasen des Forschungsprozesses gefragt sind und wie diese von der KI abgerufen werden können. Zu diesem Zweck sei Klarheit in Bezug auf das Forschungsziel und die Problemstellung erforderlich. Eine umfangreiche Expertise in der Mafo sei entscheidend, um KI-generierte Ergebnisse auf Relevanz und Stimmigkeit überprüfen zu können, und bilde die Basis für das PE. Demzufolge seien Marktforscher im Kontext des PE zu schulen, einen kritischen Verstand und Verantwortungsbewusstsein für die Ergebnisse zu entwickeln, da die Forscher letztlich für die Fehler der KI zuständig seien (1). Laut Experte 4 ist die Ausrichtung der Schulungen davon abhängig, wie das Mafo-Unternehmen das Thema PE adressieren möchte. Hierbei seien zwei Ansätze zu unterscheiden: ein Top-down-Ansatz, in dem ein verantwortlicher Leiter die prompt-technischen Initiativen vorantreibt und eine auf Mitarbeitern basierende Initiative, in der Interessierte zusammengebracht werden, um gemeinsam eine Strategie für die interne Umsetzung des PE zu entwickeln. Hierbei seien Mitarbeiter für Schulungen zu begeistern, indem reale Use-Cases für den Einsatz von PE demonstriert werden. Aus seiner Erfahrung sprechend, wissen viele nicht um die Potenziale und Vorteile von KI und PE (4). Gleichzeitig müssten die



Sorgen und Ängste der Mitarbeiter, von der KI möglicherweise ersetzt zu werden, Berücksichtigung finden und eine klare Kommunikation über das Nutzungspotenzial und die Erwartungen an die KI sei notwendig (4). Diese Erfahrung stimmt ebenfalls mit den Erkenntnissen aus dem Prompthaton überein: Aus jenem geht hervor, dass Unternehmen generell nicht ausreichend an einem Schulungsangebot für Mitarbeiter interessiert sind, weshalb Unwissenheit, Unsicherheit und Orientierungslosigkeit in diesem Bereich überwiegen. Unternehmen stünden in der Verantwortung, Richtlinien zu stellen, ebenfalls in Bezug auf ethische und datenschutzrechtliche Aspekte (Prompthaton). Die Experten 5 und 7 sowie der Prompthaton betonen die Bedeutsamkeit niedrigschwelliger Aufklärungsarbeit und den Nutzen mehrstündiger Workshops mit praktischen Übungen, in denen Interessierte mit PE-Techniken experimentieren können. Hierbei würde der Schwierigkeitsgrad der Schulung schrittweise erhöht (7). Expertin 9 hebt ebenfalls hervor, dass eine Schulung nach dem Prinzip „Learning by Doing“ gestaltet werden sollte (siehe Anhang 25), in dem die Grenzen und Möglichkeiten des Sprachmodells praktisch getestet werden. Hierbei sollte den Forschern bewusst sein, dass Fehlschläge nicht an der KI, sondern im Regelfall am Prompt oder an fehlenden Informationen liegen, sodass hier eine Sensibilisierung stattfinden sollte (9). Es sei entscheidend, den Forschern zu vergegenwärtigen, dass jeder in der Lage sei, KI mit den richtigen Methoden effizient zu bedienen (5, Prompthaton). Expertin 9 bemängelt hierbei das Fehlen eines strukturierten Vorgehens, da die meisten Unternehmen aktionistisch tätig sind und nur die wenigsten planorientiert und anwendungsfallspezifisch agieren. Da sich PE in einem Entwicklungsstadium befinde und es kein „verfestigtes“ Wissen gäbe, ist es laut Expert 6 zudem ratsam, sich fortlaufend durch Internetrecherchen weiterzubilden und sich über aktuelle Trends und Erkenntnisse von Experten zu informieren. Dies überschneidet sich mit dem Plädoyer des Prompthaton, ein kontinuierliches Lernen in Unternehmen zu fördern. Experte 8 berichtet aus seiner Unternehmenspraxis, in der eine Kultur des Selbstlernens unter den Mitarbeitern implementiert sei. Diese würden ermutigt werden, Wissen via Online-Ressourcen zu suchen und ihre Erkenntnisse intern zu teilen. Dabei erachtet der Experte 8 den Besuch externer Schulungen als nicht sinnvoll, da durch interne Schulungen das erarbeitete Wissen effizienter im Unternehmen verbreitet sowie die PE-Methoden an die unternehmensspezifischen Aufgaben optimiert werden könnten. Experte 8 sieht es hierbei als ratsam an, die verantwortlichen Mitarbeiter in einem spezialisierten Team zu organisieren, das die Richtung für den KI-Einsatz vorgibt. Dementgegen sei es nicht zielführend, wenn sämtliche Mitarbeiter eigenständig versuchen würden, sich mit PE vertraut zu machen (8).

***Glauben Sie, dass Prompt-Engineering auch in Zukunft eine relevante Kompetenz bleiben wird, oder gehen Sie davon aus, dass Fortschritte der Künstlichen Intelligenz Prompt-Engineering überflüssig machen werden?***

Experte 1 prognostiziert, dass mit der Fortentwicklung der KI der Bedarf an umfangreichen Fähigkeiten im Bereich des PE abnehmen oder sich als Allgemeinwissen etablieren wird, so dass es keine differenzierende Fähigkeit mehr darstellen wird. Dagegen erachtet die Mehrheit der Experten das PE auch zukünftig als bedeutsame Kompetenz in der Mafo verbleiben wird (2-9). Experte 2 argumentiert, dass PE weiterhin für die Generierung aussagekräftiger und sinnvoller Ergebnisse essenziell ist, da die Notwendigkeit bestehe, die Erwartungen an die KI spezifisch im Prompt zu formulieren. Zwar sei zu erwarten, dass die KI voranschreitend intelligenter würde, jedoch gäbe es in der Mafo ein breites Spektrum an Tätigkeitsfeldern, die nur mithilfe von PE zu bewältigen seien (2, 8). Ferner notiert Experte 4, dass eine höhere Autonomie der KI zu erwarten ist, insbesondere mit Blick auf Large-Action-Models, sodass sich die Dynamik von der Steuerung der KI zu einer Führung des Benutzers durch die KI verschieben könnte. Dementsprechend könnte PE nicht mehr in dem Detailgrad und in der Präzision benötigt werden, wie es derzeit der Fall sei, da die Befehle an die KI zunehmend „stupfer“ gerichtet werden könnten, womit sich die menschliche Eingabe verstärkt auf die Zielsetzung anstelle der direkten Manipulation beschränken könnte. Allerdings würde weiterhin ein „rudimentäres Basiswissen“ im PE bestehen bleiben (siehe Anhang 20), insbesondere sei dies bei komplexen Aufgaben und im B2B-Bereich der Fall. Diese würden weiterhin effektive Prompts für zuverlässige Ergebnisse benötigen, zumal der KI das unternehmensspezifische Wissen fehle. Demzufolge sei PE als Kompetenz unverändert in den Bereichen relevant, in denen fehlerfreie und aussagekräftige Ergebnisse gefragt seien (4). In diesem Sinne plädiert Experte 5 ebenfalls für die fortbestehende Relevanz des PE, da das Risiko zu hoch sei, sich einer „Black-Box“ anzuvertrauen, d. h. LLMs, deren Denkprozess nicht vollständig nachvollziehbar sei. Expertin 9 sieht es ebenfalls skeptisch, den Prozess nicht mithilfe von PE zu steuern und die KI sich selbst zu überlassen. Sie spricht sich hierbei gegen eine Übergabe des Prompt-Schreibens an die KI aus, da sich der Nutzer andernfalls zu sehr vom Prozess der Zielerreichung entkoppeln und kein Überblick über den Lösungsweg mehr bestehen würde. Die LLMs ohne PE und Validierung als Black-Box einzusetzen, wäre nur sinnvoll, wenn ihre Antworten stets fehlerfrei wären (5). Jedoch seien die KI-Modelle weit davon entfernt, diesen Zustand zu erreichen, zumal es sich bei Sprachmodellen um statistische Modelle mit inhärent variierenden Ausgaben handle (5, 7, 9). So frage sich Experte 5 (siehe Anhang 21), „ob der

*Blick hinter die Kulisse nicht noch lange nötig sein wird und ob jemand, der einen fertigen GPT bedienen kann, nicht viel zu schnell an seine Grenzen kommt, im Gegensatz zu jemandem, der weiß, wie die Prompts dahinter funktionieren, der weiß, wie man damit arbeitet und vor allem, um sich Prompts bauen zu lassen.“* Diese Perspektive teilt Experte 7, der zudem anmerkt, dass die Transformer-Architektur, die die Basis von LLMs bildet, nicht in der Lage ist, hierarchisch zu planen, sodass Prozesse nur teilweise automatisiert werden können und weiterhin das menschliche Eingreifen in Form von PE nötig ist. Ferner geht Experte 8 davon aus, dass vorläufig zusätzlich ein technischer Hintergrund für Prompt-Engineers notwendig ist, um verschiedene Softwareschnittstellen navigieren sowie integrieren zu können. Darüber hinaus betont er, dass, unabhängig davon, wie technisch der Prompt formuliert werden muss, die KI weiterhin eine klare und strukturierte Anleitung benötige.

## 11. Diskussion der Ergebnisse

Gegenstand dieses Kapitels ist es, die Ergebnisse zu reflektieren, indem die Hypothesen und die Forschungsfrage beantwortet sowie die Arbeit in den Stand der Forschung eingeordnet und ihre möglichen Limitationen beleuchtet werden.

### 11.1 Diskussion der Hypothesen

*Hypothese 1: Die Formulierung der Prompts wirkt sich auf die Qualität der Ergebnisse aus, sodass eine präzise Gestaltung der Prompts einen entscheidenden Einfluss auf die Relevanz und Genauigkeit der Informationen besitzt.*

Die erste Hypothese wird durch den Konsens unter den befragten Experten sowie durch den Prompthaton eindeutig bekräftigt. Diese besagen, dass sich die Prompt-Formulierung maßgeblich auf die Qualität der Ergebnisse auswirkt. Hierbei ist zu beachten, dass Large-Language-Models (LLMs) sensibel auf einzelne Wörter reagieren, weswegen Sorgfalt bei der Wortwahl geboten ist. Das Prompt-Engineering (PE) spielt eine zentrale Rolle, da es sich auf die zielgerichtete und systematische Entwicklung von Prompts fokussiert und als Voraussetzung für hochwertige Ergebnisse erachtet wird. Die Beachtung von PE-Methoden führt zu einer erheblichen Steigerung der Relevanz und Zuverlässigkeit der generierten Ergebnisse. Zudem wird die Konformität mit Qualitätsansprüchen sichergestellt, indem die Verhaltensweise des Modells mittels PE in die gewünschte Richtung gelenkt wird. Das kann über die Beeinflussung der LLM-Parameter erfolgen oder es werden Qualitätsstandards im Prompt selbst festgelegt. Dies schränkt zusätzlich die Gefahr von Halluzinationen ein. Darüber hinaus

ermöglicht die iterative Optimierung von Prompts, die Variabilität in den Ausgaben des LLM zu reduzieren, wodurch ein höheres Maß an Stabilität gewährleistet wird. Das PE wirkt sich unmittelbar auf den Nutzen von KI im Kontext der Marktforschung (Mafo) aus, wo die Genauigkeit und die Spezifität der Informationen einen hohen Einfluss auf den Erfolg von Analysen oder Studien ausüben. Die Experten betonen, dass ein klares Verständnis des Problems und des Forschungsziels den ersten und elementarsten Schritt für die zielgerichtete Formulierung des Prompts darstellt. Demnach erfordert effizientes PE ein adäquates Maß an Klarheit und Abstraktionsfähigkeit, um die Aufgabenstellung strukturiert und verständlich an die KI wiedergeben zu können.

Die Ergebnisse der empirischen Forschung stimmen mit dem Konsens in der Literatur überein und bestätigen somit die Erwartung dieser Arbeit, dass die Gestaltung der Prompts einen entscheidenden Einfluss auf die Qualität, Relevanz und Genauigkeit der Ergebnisse ausübt. Darauf basierend leitet die Arbeit folgende Regel ab: *Je konkreter und sorgfältiger die Prompts gestellt werden, desto genauer und hochwertiger sind die zu erwartenden Ergebnisse.* Die Arbeit unterstreicht, dass die präzise Prompt-Formulierung nicht nur für die Mafo-Branche, sondern vielmehr für jeden Bereich, in dem LLMs eingesetzt werden und hochwertige Ergebnisse erforderlich sind, entscheidend ist. Aufgrund der Ergebnisse aus der empirischen Untersuchung schlägt diese Arbeit ein Rahmenkonzept für Kriterien vor, die für eine zielgerichtete und strukturierte Gestaltung eines Prompts zu beachten sind, um zuverlässige und aussagekräftige Ergebnisse zu gewinnen. Diese orientieren sich an den Techniken und Strategien, die mehrheitlich von den Experten und dem Prompthaton hervorgehoben wurden. Abbildung 8 stellt dieses Prompt-Gerüst vor. Vor dem Beginn der primären Entwicklungsphase des Prompts ist zu empfehlen, die Einstellungen des LLM spezifisch auf den Anwendungsfall zu modifizieren, insbesondere die Temperatur-Einstellung, die den Kreativitätsgrad der Ausgaben steuert. Des Weiteren bildet die Strategie des Role-Prompting (RP) einen unkomplizierten Ansatz, um das Verhalten des LLM in die gewünschte Richtung zu beeinflussen. Diese Strategie wird zu Beginn des Prompts angewendet. Die Struktur des Prompts gliedert sich in die anfängliche Definition des Themas und der Zielstellung, die Ausrichtung der Ergebnisse an die Zielgruppe und die Beschreibung der Arbeitsschritte, die zu dem gewünschten Ergebnisformat führen. Diese Elemente sind auf das notwendige Maß an Präzision und Detailliertheit der Aufgabenstellung abzustimmen. Zudem ist der Prompt mit zusätzlichem Kontext anzureichern, der z. B. relevante Beispiele enthält, um dem Sprachmodell weitere Orientierung zu bieten. Abschließend ist es ratsam, das Modell dazu aufzufordern, Rückfragen zur Aufgabe zu

stellen, bevor es mit dem Prozess beginnt, um Unklarheiten und fehlende Informationen zu vermeiden und die Zuverlässigkeit der Ergebnisse sicherzustellen.

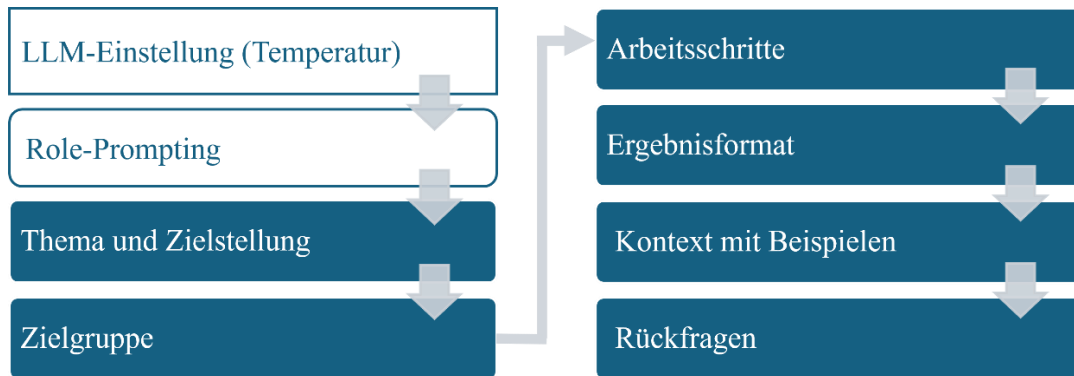


Abbildung 8: Rahmenkonzept für die strukturierte und zielgerichtete Entwicklung eines Prompts

Quelle: nach eigener Darstellung

**Hypothese 2:** *Durch den Einfluss von KI-Technologien wird eine Anpassung in der Ausbildung von Marktforschern erforderlich sein, da sie spezifische Kompetenzen im Umgang mit Sprachmodellen, insbesondere im Bereich des Prompt-Engineering, beherrschen müssen.*

Die Erkenntnisse aus den Experteninterviews und dem Prompthaton stützen ebenfalls die zweite Hypothese, indem der wachsende Einsatz von LLMs und KI im Allgemeinen als Katalysator für die Entwicklung neuer Arbeitsmethoden und Kompetenzen angesehen wird. Folglich müssen Marktforscher in ihrer Ausbildung und/oder in weiterführenden Schulungen zu einem effizienten und vorschriftsgemäßen Umgang mit KI sensibilisiert werden. Dies erfordert grundlegende Kenntnisse im PE, wobei jenes nur eine Facette im Ausbau der Digitalkompetenzen darstellt und, in Anbetracht der Expansion von KI, eine Transformation der Ausbildung erforderlich ist. Der Prompthaton und die Experten betonen die Bedeutsamkeit von Aufklärungsarbeit in Form von Schulungen für den Einsatz von KI, denn das Wissen für die korrekte und effiziente Bedienung von KI wie ChatGPT ist insgesamt zu geringfügig in der Branche verbreitet. Die Ausrichtung und das Ausmaß der Schulungen stützen sich darauf, wie Mafo-Unternehmen sich dem Thema PE widmen möchten. Abhängig von unternehmensspezifischen Anforderungen und dem Einsatzgrad der KI sind unterschiedliche Kompetenzstufen im PE gefragt, die entsprechend zu schulen sind. Hierbei muss eine klare Kommunikation stattfinden, z. B. dahingehend, wie ChatGPT die Forscher konkret unterstützen kann. Die Forscher sind aktiv zur Nutzung der KI zu motivieren und anzuleiten, um Berührungängste zu überwinden. In diesem Sinne ist es ratsam, unternehmensweite Richtlinien bereitzustellen, die eine Orientierung für den Umgang mit Sprachmodellen bieten sowie datenschutzrechtliche Aspekte

te beachten. Schulungen können in Form von mehrstündigen Workshops erfolgen, die praktische Übungen zur Erfahrungssammlung beinhalten. Diese beginnen zunächst auf einem niedrighwelligen Niveau und werden stufenweise im Schwierigkeitsgrad erhöht. Außerdem sind Marktforscher zum Selbstlernen anzuregen, wobei das gesammelte Wissen intern geteilt und strukturiert wird. Aufgrund der fortschreitenden Weiterentwicklung des PE und der hohen Dynamik im Feld der KI, besteht übergreifend die Notwendigkeit, sich stetig weiterzubilden und den Entwicklungen zu folgen. Marktforscher sind generell gefragt, die Fähigkeiten und Grenzen von LLMs zu kennen und ihre Forschungsmethoden entsprechend anzupassen. Dies bedarf eines verstärkten Fokus auf eine Kombination aus kritischem Urteilsvermögen, technischem Wissen und kreativem Denken. Zudem ist es ratsam, ein grundlegendes Verständnis für die Mechanismen hinter KI-Modellen wie ChatGPT zu gewinnen, um sie zielgerichtet zu bedienen. Auf Seiten der Forscher ist ein Bewusstsein dafür zu schulen, dass Sprachmodelle zur Generierung von Halluzinationen und Biases neigen, wodurch eine stetige Verifikation der Ergebnisse unumgänglich ist. Denn die Forscher übernehmen die Verantwortung für die generierten Ergebnisse.

Basierend auf den Erkenntnissen der empirischen Forschung schlägt diese Arbeit eine mögliche Konzeption für die Implementierung einer internen Schulung über PE in Unternehmen der Mafo-Branche vor, die in Abbildung 9 präsentiert wird. Hierbei wird das Schulungskonzept an den Strukturen des Prompthatons angelehnt. Da die Ausrichtung der Schulung abhängig von den Anforderungen des Mafo-Unternehmens und der Herangehensweise an das Thema PE ist, steht zu Beginn die Zieldefinition der Schulung. Beispielsweise verfolgt das Unternehmen das Ziel, designierten Mitarbeitern grundlegende Kompetenzen im PE zu schulen. Zu diesem Zweck wird im nächsten Schritt die Zielgruppe identifiziert, die diese Schulungen betreffen. Des Weiteren ließe sich die Zielausrichtung und die Definition der Zielgruppe nach dem quantitativen und dem qualitativen Forschungsbereich differenzieren. Die Methodik der Schulung könnte in eine theoretische und eine praktische Komponente gegliedert sein. Die Inhalte der theoretischen Einheit beginnen zunächst niedrighwellig, indem eine Einführung in die Grundlagen des PE und die Relevanz für die Mafo erfolgt. Dies wird ergänzt durch technische Schulungen, die das Funktionsprinzip sowie die Grenzen und Risiken des Sprachmodells adressieren und die Einführung von Richtlinien, die sich auf die unternehmenskonforme Interaktion mit KI beziehen. Im praktischen Segment werden PE-Techniken anhand unternehmensspezifischer Use-Cases erprobt und eigene Prompts entwickelt und getestet. Die gewonnenen Erfahrungen sind in einer Feedbackrunde zu diskutieren. Die Erkenntnisse die-

nen zur Konzeption von Best-Practices, die nach Evaluierung in Form von standardisierten Prompt-Frameworks (PF) und als offizielle Richtlinien im Unternehmen etabliert werden. Diese finalisierten Best-Practices sollten sämtlichen relevanten Mitarbeitern durch weitere Schulungen präsentiert und zur Verfügung gestellt werden, um sie im Unternehmen zu festigen und die Anforderungen an die Qualität und Zuverlässigkeit der KI-generierten Ergebnisse zu gewährleisten.

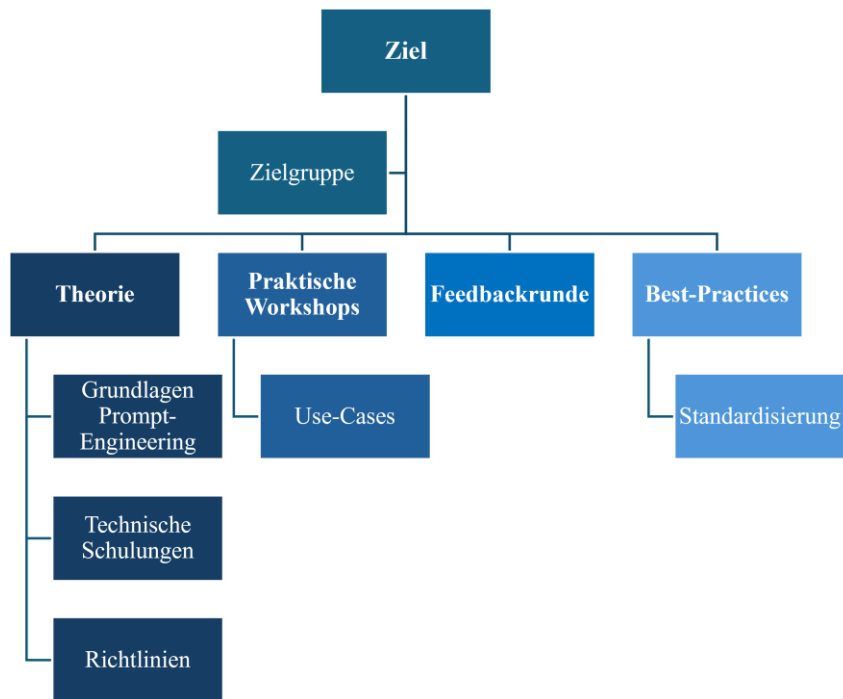


Abbildung 9: Konzeption für eine interne Schulung in Marktforschungsunternehmen

Quelle: nach eigener Darstellung

## 11.2 Beantwortung der Forschungsfrage

Die Forschungsfrage lautete: „*Steht die Marktforschung durch den Einsatz von Sprachmodellen, insbesondere ChatGPT, in der Verantwortung, Prompt-Engineering als eine neue Kompetenz zu erlernen?*“

Dem PE kommt eine ausschlaggebende Rolle in der Handhabung von LLMs und zur Generierung zuverlässiger und hochwertiger Ergebnisse zu. Allerdings präsentiert der Diskurs unter den Experten marginal abweichende Perspektiven in Bezug darauf, wie PE als Kompetenz in der Mafo zu werten ist und wie intensiv die PE-Kenntnisse zu etablieren sind. Es stellt sich die Frage, ob PE als eigenständige Kompetenz anzustreben oder vielmehr als eine ergänzende Fähigkeit zu sehen ist. Die Mehrheit der Experten sieht jedoch eine Notwendigkeit darin, PE als Kompetenz zu erwerben, um optimale Ergebnisse zu erzielen. Hierbei ist PE nicht nur für

die Mafo relevant, sondern für jeden Bereich, in dem Sprachmodelle zum Einsatz kommen. Dies bestätigen ebenfalls die Erkenntnisse aus dem Prompthaton. Insbesondere für die Mafo besteht, aufgrund des wachsenden Volumens von Text- und Datenmengen, ein klarer Bedarf, KI und die entsprechenden Digitalkompetenzen zu etablieren. Das PE ist bedeutsam, um das volle Potenzial zur Arbeitsentlastung durch KI auszuschöpfen sowie gleichzeitig eine korrekte Auswertung zu erlauben und die Genauigkeit der Forschungsergebnisse zu gewährleisten. Die Experten plädieren dafür, dass sich die Mafo an den technologischen Fortschritt anpassen und Schritt halten sollte, da andernfalls ein erheblicher Wettbewerbsnachteil riskiert wird. Potenziell werden unterschiedliche Kompetenzstufen des PE gleichzeitig im Mafo-Unternehmen vertreten sein. Insoweit ist anzunehmen, dass sich in Mafo-Unternehmen ein designiertes Team auf PE spezialisieren und für die restlichen Mitarbeiter vordefinierte Prompts sowie unternehmensspezifische GPTs zur Verfügung stellen wird. Letztere benötigen keine vertieften Kenntnisse im PE, da ein grundlegendes Verständnis für die Mehrheit der Aufgaben genügt. Die Experten unterstreichen in diesem Kontext, dass die marktforschungsspezifische Kompetenz die fundamentale Basis für prompt-technische Initiativen bildet, da sie unerlässlich ist, um die Zielstellung präzise zu formulieren und die Ergebnisse hinsichtlich ihrer Korrektheit und Relevanz zu evaluieren. In Bezug auf die Frage, ob PE zukünftig, angesichts der Fortschritte bei KI-Technologien, als eine gefragte Kompetenz fortbestehen wird, entgegnet die Experten mehrheitlich, dass dem PE weiterhin eine bedeutende Rolle in der Interaktion mit LLMs zukommen wird. Zwar wird KI intelligenter und eigenständiger, jedoch kann auf effizientes Prompting nicht verzichtet werden, um die Problemstellung zielorientiert zu formulieren und die Relevanz von Ergebnissen zu gewährleisten. Insbesondere gilt dies bei komplexen und standardisierten Aufgaben. Zudem handelt es sich bei LLMs wie ChatGPT um statistische Modelle, die nicht die Fähigkeit zum hierarchischen Planen aufweisen und deren Ausgaben inhärent variieren. Somit benötigen Sprachmodelle weiterhin eine klare und strukturierte Anleitung sowie Mechanismen des PE, die sicherstellen, dass die Ergebnisse zuverlässig und stabil sind.

### **11.3 Einordnung in den Forschungsstand und Limitationen**

PE erlebt als ein Teilgebiet der KI, insbesondere des NLP, eine dynamische Entwicklung (A.Shaji George/A. S.Hovan George 2023, S. 2). Zwar ist die Implementierung von KI-Technologien kein neues Phänomen in der Mafo (Gentsch 2018, S. 71), allerdings stellt der spezifische Einsatz von PE eine innovative Erweiterung dar. Forschungsarbeiten sind in diesem Gebiet noch begrenzt, jedoch ist eine zunehmende Anerkennung der Potenziale des PE



für die Mafo-Branche zu beobachten (Sawtooth Software 2024). Die Mehrheit der vorhandenen Studien richtet ihren Fokus auf die technischen Aspekte des PE, ohne eine umfassende Untersuchung der Anwendbarkeit in spezifischen Bereichen wie der Mafo zu thematisieren. Die vorliegende Arbeit schließt diese Forschungslücke, indem sie nicht nur das Einsatzpotenzial des PE in der Mafo betrachtet, sondern die Auswirkungen des PE auf das Kompetenzspektrum von Marktforschern analysiert. Durch die Einbeziehung von empirischen Erkenntnissen aus den Experteninterviews und der Veranstaltung Prompthaton bietet die Arbeit realitätsnahe Einblicke in die Implikationen des PE auf die Mafo. Wie alle wissenschaftlichen Arbeiten, ist auch die vorliegende Untersuchung limitiert: Zwar können hierdurch wertvolle Erkenntnisse zur Relevanz des PE für die Mafo geboten werden, jedoch ist PE per se eine junge Disziplin, die in der Branche eine geringe Adaption aufweist. Diese begrenzte Adaption könnte die Generalisierbarkeit der Forschungsergebnisse einschränken, da die Ergebnisse lediglich eine initiale Phase dieser Entwicklung darstellen könnten. Zudem stützt sich die methodologische Herangehensweise auf selektive Interviews mit Experten, die spezifische sowie persönliche Erfahrungen und Ansichten aufweisen. Diese Selektion kann nicht das Spektrum an Perspektiven, das in der Mafo existiert, vollständig abbilden und weitere relevante Einblicke berücksichtigen. Es bedarf weiterer Forschung, insbesondere da zu erwarten ist, dass das PE zunehmend in der Mafo etabliert wird und technologische Fortschritte es vermögen, die in dieser Arbeit präsentierten Erkenntnisse zu überlagern.

## 12. Fazit

Fortschritte im Natural-Language-Processing (NLP) und im Language Modeling (LM) ermöglichen die Kommunikation und Interaktion mit KI über die natürliche Sprache, wodurch der Weg für Prompt-Engineering (PE) geebnet wurde. Insbesondere durch innovative Sprachmodelle wie ChatGPT ist das PE zu einer viel diskutierten Fähigkeit geworden. Die Gestaltung des Prompts übt einen maßgeblichen Einfluss auf das Verhalten und die Qualität der Ausgaben von Sprachmodellen aus. Das PE nimmt eine zentrale Rolle hinsichtlich der Gewinnung hochwertiger, aussagekräftiger und zuverlässiger Ergebnisse ein, indem es die systematische und präzise Optimierung von Prompts adressiert. Mit dem Einzug von Large-Language-Models (LLMs) in die Marktforschung (Mafo) gewinnt PE in diesem Bereich zunehmend an Relevanz. Allerdings finden sich in der Fachliteratur kaum Arbeiten, die spezifisch die Anwendung von PE in der Mafo betrachten, weshalb diese Bachelorarbeit einen ersten Beitrag darstellt, um dieses Forschungsdefizit zu schließen. Gemäß den befragten Exper-

ten zeichnet sich das Einsatzpotenzial des PE insbesondere im qualitativen Bereich der Mafo ab. Generell ist PE in der Mafo-Branche gefragt, um schneller und zielgerichteter zu relevanten und konsistenten Ergebnissen zu finden, wodurch es den Forschungsprozess effizienter gestaltet. PE eröffnet die Möglichkeit, Aufgabenstellungen mithilfe des LLM zu lösen, für die es nicht explizit trainiert wurde und überwindet die Herausforderungen der KI, indem sie die Stabilität der Ausgaben gewährleistet. Die Forschungsfrage, ob PE als eine neue Kompetenz in der Mafo anzustreben ist, ist nach der Durchführung einer empirischen Untersuchung mehrheitlich positiv zu beantworten. Die Integration von PE in die Mafo bietet die Möglichkeit, das volle Potenzial der Sprachmodelle für den Forschungsprozess auszuschöpfen. Die Experten sehen es hierbei als realistisch an, dass sich PE in unterschiedlichen Kompetenzstufen in Mafo-Unternehmen ausprägen wird. Diese Stufen bilden ein breites Spektrum, von grundlegenden Kenntnissen in PE und KI bis zu einem tiefgreifenden Verständnis dessen für die Erstellung standardisierter Prompt-Frameworks und unternehmensspezifischer GPT-Modelle. Die Grundlage einer sinnvollen Anwendung von PE bildet in diesem Rahmen die marktforschungsspezifische Fachkompetenz. Diese ist essenziell für ein klares Verständnis der Aufgabenstellung, eine zielgerichtete Formulierung des Prompts und die Verifikation der generierten Ergebnisse. In diesem Kontext betonen die Experten, dass Marktforscher einen höheren Wert auf die Fähigkeit zur Abstraktion und ein Analysegeschick legen sollten, um den Anforderungen an effiziente Prompts zu begegnen. Die Erkenntnisse aus den Experteninterviews und dem Prompthatton weisen allerdings auf ein Defizit in diesem Bereich sowie generell auf eine Wissenslücke im effizienten Umgang mit KI-Modellen hin. Dementsprechend besteht die Notwendigkeit, nicht nur Fähigkeiten im PE zu erwerben, sondern grundsätzliche Digitalkompetenzen zu fördern und Forscher für ein kontinuierliches Lernen zu sensibilisieren. Zudem wird das Fehlen eines strukturierten und anwendungsspezifischen Vorgehens sowie das unzureichende Angebot an Schulungen für die Erwerbung von PE-Kompetenzen bemängelt. Als Antwort auf diese Problematik bietet diese Arbeit eine Konzeption für die Durchführung von PE-Schulungen an, die die Ausbildung von Marktforschern ergänzen. Dies erlaubt eine sinnvolle Interaktion mit der KI, wobei PE die Brücke zwischen Menschen und Maschine bildet. Des Weiteren wurde im Rahmen dieser Arbeit, basierend auf den Erkenntnissen der empirischen Forschung, ein Konzept für einen strukturierten Prompt erarbeitet, um den Anforderungen an die Qualität und Relevanz der Ergebnisse innerhalb der Mafo zu begegnen. Die mögliche Kritik, dass PE, angesichts der Fortschritte der KI, keine nachhaltige Kompetenz darstellt, lässt sich innerhalb der empirischen Forschung nicht bestätigen. Die Experten gehen davon aus, dass dem PE weiterhin eine Bedeutsamkeit zukommen

wird, um das Modell in die gewünschte Richtung zu steuern und die Zuverlässigkeit der Ergebnisse zu gewährleisten. Die menschliche Eingabe wird somit als ein entscheidender Erfolgsfaktor im Umgang mit KI verbleiben. Aufgrund des innovativen Charakters von PE in der Mafo, gibt es derzeit nur eine begrenzte theoretische Grundlage für diese Technologie. Diese Bachelorarbeit setzte sich zum Ziel, die Anwendungspraxis zu beleuchten, jedoch bildet die umfassende theoretische Untersuchung einen Bereich, der weiterer Forschung bedarf. In diesem Kontext wird für weitere Forschungsarbeiten plädiert, um die Etablierung des PE als eine weitere Kompetenz in der Mafo-Branche vertiefend zu analysieren. Eine weiterführende Untersuchung könnte daher prüfen, wie umfangreich die Fähigkeiten und das Wissen in den verschiedenen Kompetenzstufen des PE in der Mafo benötigt werden sowie die Entwicklung von Best-Practices. Des Weiteren sollten die Auswirkungen der Fortschritte der KI auf das PE und dessen Relevanz beobachtet werden, um validieren zu können, ob sich PE tatsächlich als eine unerlässliche und zukunftsfeste Kompetenz in der Interaktion mit LLMs erweist. Es ist anzunehmen, dass sich die Methoden und Strategien des PE kontinuierlich verbessern werden, insbesondere durch ein tiefergehendes Verständnis der Mechanismen der KI. In Zukunft könnten prompt-technische Ansätze zu einem integralen Bestandteil der Forschungsmethodik in der Mafo werden, um schneller und präziser Informationen über Kunden und Märkte zu gewinnen.

### 13. Literaturverzeichnis

Acar, O. A. (2023): AI Prompt Engineering Isn't the Future, in: Harvard Business Review, URL: <https://hbr.org/2023/06/ai-prompt-engineering-isnt-the-future> [Stand: 12.4.2024].

AISchool (2023): What are Tokens in Large Language Models?, URL: <https://artificialintelligenceschool.com/what-are-tokens-in-large-language-models/> [Stand: 18.4.2024].

Alawida, M. u. a. (2023): A Comprehensive Study of ChatGPT: Advancements, Limitations, and Ethical Considerations in Natural Language Processing and Cybersecurity, in: Information, 14. Jg., Nr. 8, S. 462, DOI: 10.3390/info14080462.

Amazon Web Services, Inc. (o. J.): Was ist GPT KI? – Generative Pre-Trained Transformers erläutert – AWS, URL: <https://aws.amazon.com/de/what-is/gpt/> [Stand: 25.3.2024].

Anadkat, S./Schulhoff, S./Yanni, F. (o. J.): Learn Prompting: Your Guide to Communicating with AI, URL: <https://learnprompting.org/> [Stand: 28.3.2024].

A.Shaji George/A. S.Hovan George (2023): The Emergence of Prompt Engineering in India: Assessing the Potential for a New Generation of AI Talent, DOI: 10.5281/ZENODO.10125681.

Backus, A. u. a. (2023): Minds: Big questions for linguistics in the age of AI, in: Linguistics in the Netherlands, 40. Jg., S. 301–308, DOI: 10.1075/avt.00094.bac.

Badhan, M. (o. J.): Comprehensive Guide to Chain-of-Thought Prompting, URL: <https://www.mercity.ai/blog-post/guide-to-chain-of-thought-prompting> [Stand: 26.4.2024].

Bahdanau, D./Cho, K./Bengio, Y. (2016): Neural Machine Translation by Jointly Learning to Align and Translate, arXiv, URL: <http://arxiv.org/abs/1409.0473> [Stand: 11.12.2023].

Bastian, M. (2023): GPT-4 hat mehr als eine Billion Parameter - Bericht, URL: <https://the-decoder.de/gpt-4-hat-eine-billion-parameter/> [Stand: 24.3.2024].

Bauer, W./Warschat, J. (2021, Hrsg.): Smart Innovation durch Natural Language Processing: mit künstlicher Intelligenz die Wettbewerbsfähigkeit verbessern, München: Hanser.

Beattie, H. u. a. (2022): Measuring and Mitigating Bias in AI-Chatbots, Fajardo, PR, USA: IEEE, DOI: 10.1109/ICAA52185.2022.00023.

Bharatha, A. (2023): Exploring the Capabilities and Limitations of ChatGPT: A Critical Look at the Recent Development in AI and Its Implications, in: International Journal of Current Research in Physiology and Pharmacology, S. 1–2.

Bhudiya, M. (2024): AI in Marketing Research: Expert Panel Discussion, Zoom, URL: [https://us02web.zoom.us/j/83001268628?tk=YrPyDHtLPex-LnLgScavcnoXygcVXVKsdM-BaWv\\_Wcps.DQYAAAATU0LZIBZPRmVoeFlpM1NxQ1dWREhzZ3R2N2F3AA&uuid=WN\\_d05pHpOYTWS0wNHnxEX5dA](https://us02web.zoom.us/j/83001268628?tk=YrPyDHtLPex-LnLgScavcnoXygcVXVKsdM-BaWv_Wcps.DQYAAAATU0LZIBZPRmVoeFlpM1NxQ1dWREhzZ3R2N2F3AA&uuid=WN_d05pHpOYTWS0wNHnxEX5dA).

Bogner, A./Littig, B./Menz, W. (2014): Interviews mit Experten: eine praxisorientierte Einführung, Wiesbaden: Springer VS, DOI: 10.1007/978-3-531-19416-5.

Böhler, H. u. a. (2022): Marktforschung, 4., erweiterte und überarbeitete Auflage. Aufl. Stuttgart: Verlag W. Kohlhammer.

Bommasani, R. u. a. (2021): On the Opportunities and Risks of Foundation Models, DOI: 10.48550/ARXIV.2108.07258.

Brandl, R. (2023): ChatGPT Statistiken und Userzahlen 2023 - OpenAI Chatbot, URL: <https://www.tooltester.com/de/blog/chatgpt-statistiken/> [Stand: 24.3.2024].

Brown, T. B. u. a. (2020): Language Models are Few-Shot Learners, arXiv, URL: <http://arxiv.org/abs/2005.14165> [Stand: 11.12.2023].

Bundesministerium der Justiz (2023): Datenschutz-Grundverordnung, URL: [https://www.bmj.de/DE/themen/digitales/DSGVO/DSGVO\\_node.html](https://www.bmj.de/DE/themen/digitales/DSGVO/DSGVO_node.html) [Stand: 30.4.2024].

Bünthe, C. (2023): So geht Digital Marketing: Tools, Tipps und Trends für die Praxis, Wiesbaden [Heidelberg]: Springer Gabler.

Carbonaro, G. (2024): Die 10 beliebtesten KI-Tools - und wer sie am häufigsten nutzt, URL: <https://de.euronews.com/next/2024/02/02/die-10-am-haufigsten-verwendeten-ki-tools-und-die-menschen-die-sie-am-haufigsten-nutzen> [Stand: 24.3.2024].

ChatGPT (2024a): Prompt: Beschreibe dich selbst., URL: <https://chat.openai.com> [Stand: 24.4.2024].

ChatGPT (2024b): Prompt: Ist ChatGPT eine schwache oder starke KI?, URL: <https://chat.openai.com> [Stand: 26.4.2024].

ChatGPT (2024c): Prompt: Wie kann ChatGPT die Marktforschungspraxis unterstützen? Unterscheide dabei die Bereiche quantitative und qualitative Marktforschung., URL: <https://chat.openai.com> [Stand: 28.4.2024].

Chen, B. u. a. (2023): Unleashing the potential of prompt engineering in Large Language Models: a comprehensive review, arXiv, URL: <http://arxiv.org/abs/2310.14735> [Stand: 9.3.2024].

Chui, M./Roberts, R./Yee, L. (2022a): Generative AI is here: How tools like ChatGPT could change your business, in: QuantumBlack, AI by McKinsey, URL: <https://www.mckinsey.com/~media/mckinsey/business%20functions/quantumblack/our%20insights/generative%20ai%20is%20here%20how%20tools%20like%20chatgpt%20could%20change%20your%20business/generative-ai-is-here-how-tools-like-chatgpt-could-change-your-business.pdf>.

Chui, M./Roberts, R./Yee, L. (2022b): Generative AI is here: How tools like ChatGPT could change your business, URL: <http://ceros.mckinsey.com/quarterly-digital-promo> [Stand: 25.3.2024].

Coursera (2024): Advanced Analytics: Definition, Benefits, and Use Cases, URL: <https://www.coursera.org/articles/advanced-analytics> [Stand: 18.4.2024].

Deng, J./Lin, Y. (2023): The Benefits and Challenges of ChatGPT: An Overview, in: *Frontiers in Computing and Intelligent Systems*, 2. Jg., Nr. 2, S. 81–83, DOI: 10.54097/fcis.v2i2.4465.

Devlin, J. u. a. (2019): BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, arXiv, URL: <http://arxiv.org/abs/1810.04805> [Stand: 11.12.2023].

Dolata, M./Lange, N./Schwabe, G. (2024): Development in times of hype: How freelancers explore Generative AI?, DOI: 10.1145/3597503.3639111.

Drăghici, D.-E. u. a. (2023): Revolutionizing Marketing Research Through AI: comprehensive review of the past, present, and future, Nr. 1, S. 39–45.

Duden (o. J.): Best Practice ► Rechtschreibung, Bedeutung, Definition, Herkunft | Duden, URL: [https://www.duden.de/rechtschreibung/Best\\_Practice](https://www.duden.de/rechtschreibung/Best_Practice) [Stand: 29.4.2024].

DZ (2024): Digitalisierungszentrum Ulm | Alb-Donau | Biberach | Neu-Ulm, URL: <https://www.digitalisierungszentrum-uab.de> [Stand: 18.4.2024].

El-Kassas, W. S. u. a. (2021): Automatic text summarization: A comprehensive survey, in: *Expert Systems with Applications*, 165. Jg., S. 113679, DOI: 10.1016/j.eswa.2020.113679.

Esposito, M. u. a. (2021): Special Issue on “Natural Language Processing: Emerging Neural Approaches and Applications”, in: *Applied Sciences*, 11. Jg., Nr. 15, S. 6717, DOI: 10.3390/app11156717.

Fabarius, W. (2023): ChatGPT in der Unternehmenspraxis: Anwendungsbeispiele für Risikomanagement, Controlling und Compliance, Berlin: Erich Schmidt Verlag.

Fitria, T. N. (2023): Artificial intelligence (AI) technology in OpenAI ChatGPT application: A review of ChatGPT in writing English essay, in: *ELT Forum: Journal of English Language Teaching*, 12. Jg., Nr. 1, S. 44–58, DOI: 10.15294/elt.v12i1.64069.

Fraiwan, M./Khasawneh, N. (2023): A Review of ChatGPT Applications in Education, Marketing, Software Engineering, and Healthcare: Benefits, Drawbacks, and Research Directions, DOI: 10.48550/ARXIV.2305.00237.

Gabel, F. (2019): Some studies in machine learning using the game of checkers - Arthur L. Samuel (1959), URL: [https://hci.iwr.uni-heidelberg.de/system/files/private/downloads/636026949/report\\_frank\\_gabel.pdf](https://hci.iwr.uni-heidelberg.de/system/files/private/downloads/636026949/report_frank_gabel.pdf).

GDPR (2023): Data Processing Agreement (DPA) complete guide for 2023 | GDPR Register, URL: <https://www.gdprregister.eu/gdpr/data-processing-agreement-dpa/> [Stand: 18.4.2024].

Gentsch, P. (2018): Künstliche Intelligenz für Sales, Marketing und Service: mit AI und Bots zu einem Algorithmic Business: Konzepte, Technologien und Best Practices, Wiesbaden [Heidelberg]: Springer Gabler, DOI: 10.1007/978-3-658-19147-4.

Gotts, I. (2023): Council Post: Prompt Engineering: Managing The Highest Risk App In Your Business, URL: <https://www.forbes.com/sites/forbestechcouncil/2023/11/02/prompt-engineering-managing-the-highest-risk-app-in-your-business/> [Stand: 28.3.2024].

Hadi, M. U. u. a. (2023): A Survey on Large Language Models: Applications, Challenges, Limitations, and Practical Usage, DOI: 10.36227/techrxiv.23589741.v1.

Härlin, T. u. a. (2023): Exploring opportunities in the gen AI value chain | McKinsey, URL: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/exploring-opportunities-in-the-generative-ai-value-chain> [Stand: 25.3.2024].

Haselhoff, V. J./Holzmüller, H. H. (2016): Qualitative Marktforschung, in: WiSt - Wirtschaftswissenschaftliches Studium, 45. Jg., Nr. 11, S. 585–589, DOI: 10.15358/0340-1650-2016-11-585.

Hecker, D. u. a. (2017): Zukunftsmarkt Künstliche Intelligenz. Potenziale und Anwendungen, DOI: 10.24406/PUBLICA-FHG-299119.

Homburg, C. (2020): Grundlagen des Marketingmanagements: Einführung in Strategie, Instrumente, Umsetzung und Unternehmensführung, 6., überarbeitete und erweiterte Auflage. Aufl. Wiesbaden [Heidelberg]: Springer Gabler, DOI: 10.1007/978-3-658-29638-4.

Hoxtell, A. (2020): Automatisierung qualitativer Marktforschung mit Künstlicher Intelligenz, in: Innovation in der Marktforschung, DOI: 10.15459/95451.44.

Huang, J./Chang, K. C.-C. (2023): Towards Reasoning in Large Language Models: A Survey, University of Illinois at Urbana-Champaign: arXiv, URL: <http://arxiv.org/abs/2212.10403> [Stand: 29.4.2024].

Hübner, M. S. (2024): EU-Parlament beschließt AI-Act: Das erste KI-Gesetz der Welt, URL: <https://www.zdf.de/nachrichten/politik/ausland/ai-act-ki-eu-parlament-gesetz-100.html> [Stand: 30.4.2024].

IBM (o. J.a): Was sind große Sprachmodelle? | IBM, URL: <https://www.ibm.com/de-de/topics/large-language-models> [Stand: 24.3.2024].

IBM (o. J.b): Was ist Natural Language Processing? | IBM, URL: <https://www.ibm.com/de-de/topics/natural-language-processing> [Stand: 25.3.2024].

IBM (o. J.c): What Is Prompt Engineering? | IBM, URL: <https://www.ibm.com/topics/prompt-engineering> [Stand: 28.3.2024].

IBM Documentation (2024a): Tips for writing foundation model prompts: prompt engineering, URL: <https://www.ibm.com/docs/en/watsonx-as-a-service?topic=lab-prompt-tips> [Stand: 12.4.2024].

IBM Documentation (2024b): Building reusable prompts, URL: <https://www.ibm.com/docs/en/watsonx-as-a-service?topic=lab-building-reusable-prompts> [Stand: 7.4.2024].

ITZ Plus (2023): Innovations- und Technologietransferzentrum ITZ Plus, URL: <https://www.itzplus.de/> [Stand: 18.4.2024].

ITZ Plus Biberach (2024): Workshop DZ Promptathon 7.3.24, URL: <https://www.itzplus.de/workshop-dz-promptathon-7324/> [Stand: 28.3.2024].

Jain, V. u. a. (2023): The Prospects and Challenges of ChatGPT on Marketing Research and Practices, in: SSRN Electronic Journal, DOI: 10.2139/ssrn.4398033.

Jöckel, L. (2024): Large Action Models (LAMs) nutzen neurosymbolische KI – Die nächste Stufe im Hype rund um Generative AI - Blog des Fraunhofer IESE, URL: <https://www.iese.fraunhofer.de/blog/large-action-models-nutzen-neurosymbolische-ki/> [Stand: 18.4.2024].

Junco, P. (2023): Council Post: The Power Of Fine-Tuning In Generative AI, URL: <https://www.forbes.com/sites/forbestechcouncil/2023/10/10/the-power-of-fine-tuning-in-generative-ai/> [Stand: 28.3.2024].

Kaddour, J. u. a. (2023): Challenges and Applications of Large Language Models, arXiv, URL: <http://arxiv.org/abs/2307.10169> [Stand: 13.3.2024].

Karty, K. (2024): AI in Marketing Research: Expert Panel Discussion, Zoom, URL: [https://us02web.zoom.us/j/83001268628?tk=YrPyDHtLPex-LnLgScavcnoXygcVXVKSdM-BaWv\\_Wcps.DQYAAAATU0LZIBZPRmVoeFlpM1NxQ1dWREhzZ3R2N2F3AA&uuid=WN\\_d05pHpOYTWS0wNHnxEX5dA](https://us02web.zoom.us/j/83001268628?tk=YrPyDHtLPex-LnLgScavcnoXygcVXVKSdM-BaWv_Wcps.DQYAAAATU0LZIBZPRmVoeFlpM1NxQ1dWREhzZ3R2N2F3AA&uuid=WN_d05pHpOYTWS0wNHnxEX5dA).

Kashyap, P. (2024): Machine Learning for Decision Makers: Cognitive Computing Fundamentals for Better Decision Making, Berkeley, CA: Apress, DOI: 10.1007/978-1-4842-9801-5.

Kavlakoglu, E. (2020): NLP vs. NLU vs. NLG: the differences between three natural language processing concepts, URL: <https://www.ibm.com/blog/nlp-vs-nlu-vs-nlg-the-differences-between-three-natural-language-processing-concepts/www.ibm.com/blog/nlp-vs-nlu-vs-nlg-the-differences-between-three-natural-language-processing-concepts> [Stand: 25.3.2024].

Kelbert, D. J. S., Thorsten Honroth, Patricia (2024): Prompt Engineering: wie man mit großen Sprachmodellen kommuniziert - Blog des Fraunhofer IESE, URL: <https://www.iese.fraunhofer.de/blog/was-ist-prompt-engineering/> [Stand: 6.4.2024].

Kepper, G. (2008): Methoden der qualitativen Marktforschung, in: Handbuch Marktforschung : Methoden, Anwendungen, Praxisbeispiele,.

Klimczak, P./Petersen, C. (2023, Hrsg.): AI - limits and prospects of artificial intelligence, Bielefeld: transcript.

Koch, J./Riedmüller, F. (2021): Marktforschung: Grundlagen und praktische Anwendungen, 8., vollständig überarbeitete Auflage. Aufl. Berlin ; Boston: De Gruyter Oldenbourg.

Kong, A. u. a. (2023): Better Zero-Shot Reasoning with Role-Play Prompting, arXiv, URL: <http://arxiv.org/abs/2308.07702> [Stand: 9.3.2024].

Koubaa, A. u. a. (2023): Exploring ChatGPT Capabilities and Limitations: A Survey, in: IEEE Access, 11. Jg., S. 118698–118721, DOI: 10.1109/ACCESS.2023.3326474.



Kreis, H./Wildner, R./Kuß, A. (2021): Marktforschung: Datenerhebung und Datenanalyse, 7., überarbeitete Auflage. Aufl. Wiesbaden [Heidelberg]: Springer Gabler, DOI: 10.1007/978-3-658-32459-9.

Kühl, S./Strodtholz, P./Taffertshofer, A. (2009, Hrsg.): Handbuch Methoden der Organisationsforschung: quantitative und qualitative Methoden, 1. Auflage. Aufl. Wiesbaden: VS, Verlag für Sozialwissenschaften.

Kumar, E. (2011): Natural language processing, New Delhi: I.K. International Publishing House.

Küpeli, S. (2024): Use Case: Definition, Beispiele & Nutzen, URL: <https://www.pureconsultant.de/de/wissen/use-case/> [Stand: 29.4.2024].

Lamb, J. (2023): Council Post: In The Age Of AI, Everything Is An API, URL: <https://www.forbes.com/sites/forbestechcouncil/2023/09/18/in-the-age-of-ai-everything-is-an-api/> [Stand: 25.3.2024].

Lim, R./Wu, M./Miller, L. (2021): Customizing GPT-3 for your application, URL: <https://openai.com/blog/customizing-gpt-3> [Stand: 26.4.2024].

Lippold, D. (2015): Theoretische Ansätze der Marketingwissenschaft: ein Überblick, Wiesbaden: Springer-Gabler.

Liu, Y./Lapata, M. (2019): Text Summarization with Pretrained Encoders, arXiv, URL: <http://arxiv.org/abs/1908.08345> [Stand: 11.12.2023].

Lund, B./Ting, W. (2023): Chatting about ChatGPT: How May AI and GPT Impact Academia and Libraries?, in: SSRN Electronic Journal, DOI: 10.2139/ssrn.4333415.

Luz, S. (2022): Computational linguistics and Natural Language Processing, The Routledge Handbook of Translation and Methodology Computational linguistics and Natural Language Processing, 1. Aufl., London, DOI: 10.4324/9781315158945.

Mallikarjunaradhya, V./Pothukuchi, A. S. (2021): The Future of SAAS Startups: How AI Accelerates Market Research and Product Development, in: Asian Journal of Multidisciplinary Research & Review (AJMRR), 2. Jg., Nr. 4, S. 444–450.

Manghani, S. (2024): Prompt Engineering, Explained, URL: <https://medium.com/electronic-life/prompt-engineering-explained-3b83ba347722> [Stand: 12.4.2024].

Marr, B. (2023): The Top 10 Limitations Of ChatGPT, URL: <https://www.forbes.com/sites/bernardmarr/2023/03/03/the-top-10-limitations-of-chatgpt/> [Stand: 28.3.2024].

Marr, B. (2024): AI Showdown: ChatGPT Vs. Google’s Gemini – Which Reigns Supreme?, URL: <https://www.forbes.com/sites/bernardmarr/2024/02/13/ai-showdown-chatgpt-vs-googles-gemini--which-reigns-supreme/> [Stand: 24.3.2024].

Martinez, J. J. (2023): Supervised Fine-tuning: customizing LLMs, URL: <https://medium.com/mantisnlp/supervised-fine-tuning-customizing-llms-a2c1edbf22c3> [Stand: 18.4.2024].

Maslej-Krešňáková, V. u. a. (2020): Comparison of Deep Learning Models and Various Text Pre-Processing Techniques for the Toxic Comments Classification, in: Applied Sciences, 10. Jg., Nr. 23, S. 8631, DOI: 10.3390/app10238631.

Mehta, D. (2023): Erklärbare KI: Das Geheimnis der Blackbox lüften, URL: <https://blog.iao.fraunhofer.de/erklaerbare-ki-das-geheimnis-der-blackbox-lueften/> [Stand: 18.4.2024].

Merriam-Webster (2024): Definition of CPU, URL: <https://www.merriam-webster.com/dictionary/CPU> [Stand: 18.4.2024].

Merritt, R. (2022): What Is a Transformer Model?, URL: <https://blogs.nvidia.com/blog/what-is-a-transformer-model/> [Stand: 25.3.2024].

Mhlanga, D. (2023): Open AI in Education, the Responsible and Ethical Use of ChatGPT Towards Lifelong Learning, in: SSRN Electronic Journal, DOI: 10.2139/ssrn.4354422.

Misoch, S. (2015): Qualitative Interviews, Berlin München Boston: de Gruyter Oldenbourg.

Mittal, A. (2023): Der wesentliche Leitfaden für Prompt Engineering in ChatGPT – Unite.AI, URL: <https://www.unite.ai/de/promptes-Engineering-in-Chatgpt/> [Stand: 28.3.2024].

Mittal, M. (2024): Prompt Engineering Deep Dive: Mastering the RISE Framework | LinkedIn, URL: <https://www.linkedin.com/pulse/prompt-engineering-deep-dive-mastering-rise-framework-madhuri-mittal-8lxcc/> [Stand: 16.4.2024].

Mollick, E. (2023): Captain’s log: the irreducible weirdness of prompting AIs, URL: <https://www.oneusefulthing.org/p/captains-log-the-irreducible-weirdness> [Stand: 28.3.2024].

Mühlbauer, D. (2023): ChatGPT: Warum Prompt Engineering entscheidend ist!, URL: <https://www.hr-datenliebe.de/post/chatgpt-warum-prompt-engineering-entscheidend-ist> [Stand: 28.3.2024].

Muneer, M./Maad, M./Hussain, S. (2023): How Chatgpt is Playing a Role in Artificial Intelligent bases Applications.

Mustafa, N. (2024): Mastering ChatGPT: Boost Your Creativity with Expert Prompt Engineering Techniques, URL: <https://ai.plainenglish.io/mastering-chatgpt-boost-your-creativity-with-expert-prompt-engineering-techniques-c702c9141afd> [Stand: 7.4.2024].

O’Neill, M./Connor, M. (2023): Amplifying Limitations, Harms and Risks of Large Language Models, arXiv, URL: <http://arxiv.org/abs/2307.04821> [Stand: 21.3.2024].

OpenAI (2022): Introducing ChatGPT, URL: <https://openai.com/blog/chatgpt> [Stand: 25.3.2024].

OpenAI (2023): GPT-4, URL: <https://openai.com/research/gpt-4>.

OpenAI (o. J.a): About, URL: <https://openai.com/about> [Stand: 22.1.2024].

OpenAI (o. J.b): Our structure, URL: <https://openai.com/our-structure> [Stand: 22.1.2024].

- OpenAI (o. J.c): Safety & responsibility, URL: <https://openai.com/safety> [Stand: 22.1.2024].
- OpenAI u. a. (2024): GPT-4 Technical Report, arXiv, URL: <http://arxiv.org/abs/2303.08774> [Stand: 28.3.2024].
- OpenAI (o. J.d): Best practices for prompt engineering with the OpenAI API | OpenAI Help Center, URL: <https://help.openai.com/en/articles/6654000-best-practices-for-prompt-engineering-with-the-openai-api> [Stand: 28.3.2024].
- OpenAI (o. J.e): OpenAI Platform: Prompt engineering, URL: <https://platform.openai.com> [Stand: 28.3.2024].
- Paass, G./Giesselbach, S. (2023): Foundation models for natural language processing: pre-trained language models integrating media, Cham: Springer.
- Pawlan, D. (2023): Council Post: Prompt Engineering: The Next Wave Of Skillsets, URL: <https://www.forbes.com/sites/forbestechcouncil/2023/12/22/prompt-engineering-the-next-wave-of-skillsets/> [Stand: 28.3.2024].
- Pulyaev, Y. (2024): NLP vs LLM: Main Differences Between Natural Language Processing and Large Language Models - Springs, URL: <https://springsapps.com/knowledge/nlp-vs-llm-main-differences-between-natural-language-processing-and-large-language-models>, <https://springsapps.ai/blog/nlp-vs-llm-main-differences-between-natural-language-processing-and-large-language-models> [Stand: 16.4.2024].
- Radford, A. u. a. (2019): Language Models are Unsupervised Multitask Learners, URL: [@inproceedings{Radford2019LanguageMA, title={Language Models are Unsupervised Multitask Learners}, author={Alec Radford and Jeff Wu and Rewon Child and David Luan and Dario Amodei and Ilya Sutskever}, yehtps://api.semanticscholar.org/CorpusID:160025533](https://api.semanticscholar.org/CorpusID:160025533).
- Ranathunga, S. u. a. (2021): Neural Machine Translation for Low-Resource Languages: A Survey, DOI: 10.48550/ARXIV.2106.15115.
- Saravia, E. (o. J.a): Allgemeine Tipps für das Entwerfen von Prompts – Nextra, URL: <https://www.promptingguide.ai/de/introduction/tips> [Stand: 28.3.2024].
- Saravia, E. (o. J.b): LLM Einstellungen – Nextra, URL: <https://www.promptingguide.ai/de/introduction/settings> [Stand: 28.3.2024].
- Saravia, E. (2024): Elemente eines Prompts – Nextra, URL: <https://www.promptingguide.ai/de/introduction/elements> [Stand: 12.4.2024].
- Sasaki, F./Witt, A. (2004): Linguistische Korpora, Texttechnologie. Perspektiven und Anwendungen, Stauffenburg: Stauffenburg Verlag, S. 195–216.
- Saturn Cloud (2023): Unsupervised Pre-training, URL: <https://saturncloud.io/glossary/unsupervised-pretraining/> [Stand: 18.4.2024].
- Sawtooth Software (2024): AI in Marketing Research: Expert Panel Discussion, Zoom, URL: <https://us02web.zoom.us/j/83001268628?tk=YrPyDHtLPex-LnLgScavcnoXygcVXVKSdM->

BaWv\_Wcps.DQYAAAATU0LZIBZPRmVoeFlpM1NxQ1dWREhzZ3R2N2F3AAAAAAA  
AAAAAAA&uuid=WN\_d05pHpOYTWS0wNHnx  
EX5dA.

Schneider, P. (2023): Künstliche Intelligenz, in: Heise Medien GmbH & Co. KG, iX Special 2023. Jg., Künstliche Intelligenz, S. 102–104.

Severino, I. (2024): Mastering Prompt Frameworks for Language Models: A Comprehensive Guide, URL: [https://medium.com/@Ivan\\_S/mastering-prompt-frameworks-for-language-models-a-comprehensive-guide-522c509b2dcb](https://medium.com/@Ivan_S/mastering-prompt-frameworks-for-language-models-a-comprehensive-guide-522c509b2dcb) [Stand: 7.4.2024].

Skill Leap AI (2023): 2.4 Shot Prompting - Understanding and Applying Shot Prompting, URL: <https://skillleap.ai/pages/skill-leap-ai-platform> [Stand: 28.3.2024].

Sloyan, T. (2023): Council Post: What You Need To Know About Prompt Engineers—And Why You Might Want One, URL: <https://www.forbes.com/sites/forbestechcouncil/2023/11/22/what-you-need-to-know-about-prompt-engineers-and-why-you-might-want-one/> [Stand: 6.4.2024].

Sohail, S. S. u. a. (2023): Decoding ChatGPT: A Taxonomy of Existing Research, Current Challenges, and Possible Future Directions, in: Journal of King Saud University - Computer and Information Sciences, 35. Jg., Nr. 8, S. 101675, DOI: 10.1016/j.jksuci.2023.101675.

Steinmann, N./Piazza, A. (2024): KI-basierte Textkreation im Content Marketing: Design und Evaluation eines effektiven Prompts, in: HMD Praxis der Wirtschaftsinformatik, 61. Jg., Nr. 2, S. 402–417, DOI: 10.1365/s40702-024-01058-3.

Stoetzer, M.-W. (2020): Regressionsanalyse in der empirischen Wirtschafts- und Sozialforschung. Band 2: Komplexe Verfahren / Matthias-W. Stoetzer, Berlin [Heidelberg]: Springer.

Sudirjo, F. u. a. (2023): Application of ChatGPT in Improving Customer Sentiment Analysis for Businesses, in: Jurnal Teknologi Dan Sistem Informasi Bisnis, 5. Jg., Nr. 3, S. 283–288, DOI: 10.47233/jteksis.v5i3.871.

Sudmann, A. u. a. (2023, Hrsg.): Beyond quantity: research with subsymbolic AI, Bielefeld: transcript.

Taulli, T. (2019): Artificial intelligence basics: a non-technical introduction, New York: Ap-ress, DOI: 10.1007/978-1-4842-5028-0.

Terstiege, M. (2021, Hrsg.): KI in Marketing & Sales - Erfolgsmodelle aus Forschung und Praxis: Konzepte und Instrumente zum erfolgreichen Einsatz künstlicher Intelligenz, Wiesbaden [Heidelberg]: Springer Gabler.

Toews, R. (2023): Transformers Revolutionized AI. What Will Replace Them?, URL: <https://www.forbes.com/sites/robtoews/2023/09/03/transformers-revolutionized-ai-what-will-replace-them/> [Stand: 25.3.2024].

Törnberg, P. (2024): Best Practices for Text Annotation with Large Language Models, arXiv, URL: <http://arxiv.org/abs/2402.05129> [Stand: 11.2.2024].

- Wagener, A. (2023): Künstliche Intelligenz im Marketing: was sich hinter KI verbirgt und wie das Marketing von ihr profitieren kann, 2. Auflage. Aufl. Freiburg München Stuttgart: Haufe Group.
- Wang, H. u. a. (2023): Pre-Trained Language Models and Their Applications, in: Engineering, 25. Jg., S. 51–65, DOI: 10.1016/j.eng.2022.04.024.
- Wang, R. u. a. (2024): Role Prompting Guided Domain Adaptation with General Capability Preserve for Large Language Models, arXiv, URL: <http://arxiv.org/abs/2403.02756> [Stand: 9.3.2024].
- Weber, F. (2024): Wie KI-basierte Methoden die Marktforschung verändern, URL: <https://www.marktforschung.de/marktforschung/a/wie-ki-basierte-methoden-die-marktforschung-veraendern/> [Stand: 25.3.2024].
- Weber, M./Reichardt, M. (2023): Evaluation is all you need. Prompting Generative Large Language Models for Annotation Tasks in the Social Sciences. A Primer using Open Models, arXiv, URL: <http://arxiv.org/abs/2401.00284> [Stand: 11.2.2024].
- Wei, J. u. a. (2023): Chain-of-Thought Prompting Elicits Reasoning in Large Language Models, arXiv, URL: <http://arxiv.org/abs/2201.11903> [Stand: 6.3.2024].
- Wheeler, G. (2016): MACHINE EPISTEMOLOGY AND BIG DATA, The Routledge Companion to Philosophy of Social Science, 1. Aufl., New York: Routledge.
- White, J. u. a. (2023a): A Prompt Pattern Catalog to Enhance Prompt Engineering with ChatGPT, arXiv, URL: <http://arxiv.org/abs/2302.11382> [Stand: 18.4.2024].
- White, J. u. a. (2023b): ChatGPT Prompt Patterns for Improving Code Quality, Refactoring, Requirements Elicitation, and Software Design, arXiv, URL: <http://arxiv.org/abs/2303.07839> [Stand: 11.2.2024].
- Whiting, K. (2023): 3 new and emerging jobs you can get hired for this year, URL: <https://www.weforum.org/agenda/2023/03/new-emerging-jobs-work-skills/> [Stand: 12.4.2024].
- Williams, A. (2024): Application Programming Interfaces (APIs) Explained, URL: <https://www.forbes.com/sites/technology/article/what-is-an-api/> [Stand: 25.3.2024].
- Woppmann, A. (2024): ChatGPT im Praxistest - Auswertung offener Nennungen durch eine KI, URL: <https://www.marktforschung.de/marktforschung/a/chatgpt-im-praxistest-auswertung-offener-nennungen-durch-eine-ki/> [Stand: 25.3.2024].
- Wu, X./Duan, R./Ni, J. (2023): Unveiling Security, Privacy, and Ethical Concerns of ChatGPT, in: Journal of Information and Intelligence, S. S2949715923000707, DOI: 10.1016/j.jiixd.2023.10.007.
- Yang, X. u. a. (2021): Unsupervised Pre-training with Structured Knowledge for Improving Natural Language Inference, arXiv, URL: <http://arxiv.org/abs/2109.03941> [Stand: 18.4.2024].

Yenduri, G. u. a. (2023): Generative Pre-trained Transformer: A Comprehensive Review on Enabling Technologies, Potential Applications, Emerging Challenges, and Future Directions, arXiv, URL: <http://arxiv.org/abs/2305.10435> [Stand: 3.3.2024].

Youngblood, D. (2023): Master Prompt Templating — for AI and LLMs, URL: <https://medium.com/@thedavidyoungblood/master-prompt-templating-for-ai-and-llms-3f993f896d8f> [Stand: 7.4.2024].

Zhang, S. u. a. (2024): Instruction Tuning for Large Language Models: A Survey, arXiv, URL: <http://arxiv.org/abs/2308.10792> [Stand: 28.4.2024].

Zhao, W. X. u. a. (2023): A Survey of Large Language Models, arXiv, URL: <http://arxiv.org/abs/2303.18223> [Stand: 4.1.2024].

Zheng, H. u. a. (2023): Learn From Model Beyond Fine-Tuning: A Survey, arXiv, URL: <http://arxiv.org/abs/2310.08184> [Stand: 28.3.2024].

## **14. Übersicht verwendeter Hilfsmittel**

Im Rahmen dieser Arbeit wurde das Sprachmodell „ChatGPT“, im Spezifischen die Modell-Version GPT-3.5, verwendet, um einen Einblick in seine sprachliche Generierungsfähigkeit zu eröffnen sowie das Modell selbst zu Wort kommen zu lassen. Die KI-generierten Texte sind kursiv gekennzeichnet und mit einer Quellenangabe angegeben, die im Literaturverzeichnis mit dem entsprechenden Prompt aufgeführt sind.

## **XIV. Anhang**

### **Anhangsverzeichnis**

Anhang 1: Unterscheidung in schwache KI und starke KI .....	80
Anhang 2: Machine-Learning .....	81
Anhang 3: Deep-Learning .....	82
Anhang 4: Foundation-Model .....	83
Anhang 5: Transformer-Model.....	84
Anhang 6: Generative-AI.....	85
Anhang 7: Generative-Pre-trained-Transfomers .....	86
Anhang 8: Entwicklung von ChatGPT.....	87
Anhang 9: OpenAI .....	90
Anhang 10: Anwendungsgebiete von ChatGPT in der der Marktforschung nach ChatGPT ...	91
Anhang 11: Weitere Prompt-Engineering-Strategien.....	92
Anhang 12: Large-Language-Model-Einstellungen.....	93
Anhang 13: Prompt-Engineering vs. Fine-Tuning .....	95
Anhang 14: Prompthaton .....	96
Anhang 15: Leitfaden Experteninterviews.....	99
Anhang 16: Zusätzliche Untersuchungsfelder aus der empirischen Forschung .....	101

## Anhang 1: Unterscheidung in schwache KI und starke KI

Im Bereich der KI wird vielfach eine Differenzierung zwischen „starker KI“ und „schwacher KI“ gezogen. „Schwache KI“, im Englischen als Applied-Artificial-Intelligence bzw. „Angewandte KI“ bekannt, bezeichnet die automatisierte Abwicklung spezifischer Anwendungsgebiete und die Problemlösungen durch intelligente Systeme. Diese weisen einen begrenzten Grad an Selbständigkeit in der Entscheidungsfindung sowie bei der Durchführung von resultierenden Aktionen auf. Somit ist unter „schwacher KI“ ein „Nachahmen“ von Intelligenz zu verstehen, die die Mehrheit der geläufigen KI-Applikationen umfasst, darunter die Text- oder Bilderkennung. Dagegen schließt „starke KI“, im Englischen Artificial-General-Intelligence bzw. „Künstliche Allgemeine Intelligenz“, die authentische Rekonstruktion des menschlichen Denkprozesses sowie die Fähigkeit zur Abstraktion ein und bezeichnet in einigen Fällen die Entfaltung eines eigenen „Bewusstseins“. Dementsprechend ist mit „starker KI“ die Vorstellung verbunden, dass KI zukünftig nicht nur die menschlichen Fähigkeiten vollkommen abbilden, sondern sie sogar übertreffen werden. Hiermit ist die vielbesprochene Thematik der Singularität eng verknüpft, die den Zeitpunkt charakterisiert, an dem die KI den Menschen in Form von Maschinen, Robotern oder Softwaresystemen bezüglich ihrer kognitiven Leistungsfähigkeit einholt (Wagener 2023, S. 20). Wird ChatGPT gefragt, in welche Kategorisierung sich das KI-Modell selbst einstuft, wird folgende Antwort generiert:

*„ChatGPT ist eine Form von schwacher künstlicher Intelligenz (KI). Es ist darauf spezialisiert, natürliche Sprache zu verstehen und zu generieren, aber es hat keine umfassenden kognitiven Fähigkeiten oder ein umfassendes Verständnis der Welt. Im Gegensatz dazu würde eine starke künstliche Intelligenz ein breiteres Spektrum von Aufgaben mit menschenähnlicher Intelligenz bewältigen können, einschließlich tiefem Verständnis, Lernen über verschiedene Domänen und eigenständigem Problemlösen. ChatGPT ist jedoch auf spezifische Anwendungen begrenzt und erfordert klare Anweisungen, während eine starke KI autonomer und flexibler wäre.“ (ChatGPT 2024b)*



## **Anhang 2: Machine-Learning**

Das Konzept des maschinellen Lernens ist auf Arthur L. Samuel zurückzuführen, der das erste Beispiel eines Machine-Learning-Systems, nämlich das auf Computer angewandte Spiel Checkers, programmierte und den Begriff des „Machine-Learning“ (ML) im Jahr 1959 einführte (Gabel 2019, S. 8; Taulli 2019, S. 41). Mithilfe des ML werden Maschinen befähigt, kontinuierlich zu lernen und sich zu verbessern, indem die Datenverarbeitung, ohne die Erforderlichkeit einer vorherig expliziten Programmierung, stattfindet (Taulli 2019, S. 41–42). Dies wird durch die Nutzung von fortgeschrittenen Methoden der Statistik, insbesondere der Wahrscheinlichkeitsanalyse, ermöglicht. Zu diesem Zweck erstellt ein ML-Algorithmus ein auf Trainingsdaten basierendes statistisches Modell, bei dem die vorgegebenen Beispiele nicht nur auswendig gelernt, sondern vielmehr Muster und Regelmäßigkeiten in den Daten identifiziert werden. Dementsprechend kann das ML-Modell auch nicht identifizierte Daten verarbeiten (Kashyap 2024, S. 6). ML gliedert sich dem Feld der KI unter, laut Wheeler (2016, S. 2) ist ML „a marriage of statistics and computer science that began in artificial intelligence.“ KI und im Spezifischen ML erfuhren in den letzten Jahren erhebliche Fortschritte und ermöglichten vorherig undenkbare Anwendungen. Zudem haben insbesondere Weiterentwicklungen in einem Teilgebiet des ML, das Deep-Learning (DL) (Taulli 2019, S. 71), zahlreiche Bereiche transformiert und u. a. herausragende Leistungen in der natürlichen Sprachverarbeitung (NLP) erzielt, wie das semantische Textverständnis, die Texterstellung und Textkategorisierung sowie die automatische Beantwortung von Fragen (Klimczak/Petersen 2023, S. 43).

### **Anhang 3: Deep-Learning**

Als Deep-Learning (DL) wird das spezialisierte Teilgebiet des ML beschrieben, das sich auf Künstliche Neuronale Netze (KNN) stützt, die über viele Schichten, die sogenannten tiefen Netzwerke, verfügen (Klimczak/Petersen 2023, S. 43). Die Bezeichnung „Deep“ begründet sich aus der Anzahl an versteckten Schichten in diesem neuronalen Netz, die für den Großteil der Lernfähigkeit verantwortlich sind. Hierfür werden KNN trainiert, wobei Knoten die künstlichen Neuronen darstellen. Diese verfügen über eine Aktivierungsfunktion, die bestimmt, ob und wie der Knoten die jeweiligen Signale im Zahlenformat weitergibt, die er von seinen Vorgängerknoten empfängt (Hecker u. a. 2017, S. 8). Im Gegensatz zu den ersten KNN, die lediglich aus einer Eingabe-, Ausgabe- und eventuell aus einer Zwischenschicht bestanden, weisen tiefe Netze gegenwärtig Hunderte von Schichten sowie „Milliarden von zu lernenden Gewichten zwischen den Knoten“ (Hecker u. a. 2017, S. 9) auf. Dieses System ermöglicht die Verarbeitung von großen Datenmengen, um, vergleichbar mit ML, komplexe Muster und Beziehungen innerhalb dieser Daten zu erkennen, die für den Menschen nicht ersichtlich wären (Klimczak/Petersen 2023, S. 44; Taulli 2019, S. 71). KNN sind in der Lage, sämtliche Arten von Rohdaten zu verarbeiten, sofern sie als Zahlenvektoren codiert werden, beispielsweise Wörter über ihre Position in Wörterbüchern oder Bilder in Form von Pixeln (Hecker u. a. 2017, S. 9). Das DL trug signifikant dazu bei, dass KI ihre jüngsten Errungenschaften, u. a. im Sprach- und Bildverstehen, erreichen konnten (Hecker u. a. 2017, S. 8).

#### **Anhang 4: Foundation-Model**

Foundation-Models, zu Deutsch Grundlagenmodelle, sind DL-Modelle, die mit massiven, unstrukturierten Datensätzen, wie in Text- oder Bildform, trainiert sind und eine Vielzahl an Themen beinhalten (Chui/Roberts/Yee 2022a, S. 2). Unter FMs sind im Grunde jegliche KI-Modelle zu verstehen, die ein Training auf einer umfangreichen Datenbasis aufweisen und die Adaption an ein breites Spektrum an Aufgaben erlauben (Bommasani u. a. 2021, S. 3). Dementsprechend werden sie ebenfalls als „Allzweckmodelle“ bezeichnet (Dolata/Lange/Schwabe 2024, S. 2). FMs haben insbesondere im Bereich des Natural-Language-Processing (NLP) Verbreitung gefunden (Bommasani u. a. 2021, S. 4). Sie sind in der Lage, Inhalte zu generieren und bieten den Vorteil, von Entwicklern an zahlreiche Anwendungsfälle flexibel adaptiert zu werden, ohne die Erforderlichkeit einer umfassenden Feinabstimmung. Dadurch ist die Leistungsstärke dieser Modelle für diejenigen zugänglich, die einen begrenzten technischen Hintergrund aufweisen. Zudem reduziert der Einsatz von FMs die zeitlichen Ressourcen für die Entwicklung neuer KI-Anwendungen erheblich (Chui/Roberts/Yee 2022a, S. 2). Als bekannte Beispiele für FMs sind GPT-3 und GPT-4 von OpenAI zu erwähnen (Härlin u. a. 2023). Zwar unterstützen FMs die Ausführung von einer Vielzahl an Aufgaben, allerdings sind es zumeist die darauf errichteten Anwendungen, die die Bearbeitung spezifischer Aufgaben ermöglichen, wie beispielsweise der Kundensupport bei Serviceproblemen (Härlin u. a. 2023).

## **Anhang 5: Transformer-Model**

Ein Transformer-Model (TM) ist ein Künstlich Neuronales Netz (KNN), das in der Lage ist, den Kontext sowie ein semantisches Verständnis zu erwerben, indem es die Zusammenhänge innerhalb sequenzieller Daten, z. B. Wörter innerhalb eines Satzes, analysiert. TMs nutzen eine wachsende Reihe an mathematischen Methoden, die als Aufmerksamkeits- oder Selbst-aufmerksamkeitsmechanismen (Attention- or Self-attention-Mechanisms) bezeichnet werden. Diese ermöglichen die Identifikation von nuancierten Beziehungen zwischen den Datenelementen in einer Sequenz, selbst diejenigen, die weit voneinander entfernt sind (Toews 2023; Merritt 2022). Erstmals in einem Artikel von Google im Jahr 2017 beschrieben, gehören TMs zu den modernsten und leistungsfähigsten Modellklassen, die bisher entwickelt wurden. Mit ihrem Aufkommen haben sie eine Welle an Fortschritten im Bereich des ML vorangetrieben (Merritt 2022), wobei die grundlegende Innovation der TMs in ihrem Aufmerksamkeitsmechanismus besteht. Dieser ermöglicht die Parallelisierung der Sprachverarbeitung, wodurch alle Wörter in einem Textfeld nicht nacheinander, sondern gleichzeitig analysiert werden (Toews 2023). Damit wird die Bedeutung eines jeden einzelnen Wortes unabhängig von seiner Position in der Eingabesequenz erlernt, was insbesondere relevant für NLP-Aufgaben wie die Fragebeantwortung ist, bei denen der Sinngehalt eines Satzes von den weit auseinander liegenden Wörtern abhängen kann (Hadi u. a. 2023, S. 4). Diese Parallelisierung ermächtigen TMs zu einem globaleren und damit präziseren Verständnis der Texte, die sie lesen und selbst generieren. Ebenso sind sie skalierbarer sowie recheneffizienter als vorherige Modellklassen. Zudem bieten TMs den Vorteil, mit massiveren Datensätzen trainiert und mit einem höheren Satz an Parametern als vorherige Architekturen entwickelt zu werden, wodurch sie leistungsfähiger und verallgemeinerbarer sind. Während TMs ursprünglich spezifisch für die Sprachübersetzung programmiert wurden, sind sie universell einsetzbar und beschleunigen den Stand der Technik. Zusätzlich bilden TMs die Basis für Chatbots, darunter beliebte Modelle wie ChatGPT von OpenAI, Googles Bard und Bing Chat von Microsoft (Toews 2023).

**Anhang 6: Generative-AI**

Generative-AIs (GenAI) basieren auf FMs und beschreiben im Wesentlichen KI-Systeme, die sich durch ihre Fähigkeit auszeichnen, neuartige Inhalte aus Anweisungen oder Beispielen zu generieren (Dolata/Lange/Schwabe 2024, S. 2; Härlin u. a. 2023), die die Merkmale und Muster der Trainingsdaten reproduzieren (Hadi u. a. 2023, S. 3). Diese Inhalte werden in Text, Bild-, Video- oder Audioformat ausgegeben. GenAIs verbinden statistische Modelle mit komplexen Algorithmen (Hadi u. a. 2023, S. 3–4). Hierbei bewirkt eine stochastische Schicht im Model, dass GenAIs nicht-deterministische Ausgaben erzeugen, sodass z. B. eine Vorhersage zu treffen, welches Bild aus einem Satz an Beispielen generiert wird, nicht möglich ist und somit die Illusion von Kreativität entsteht (Dolata/Lange/Schwabe 2024, S. 2). Einige bekannte Beispiele für GenAIs in diesen Bereichen sind u. a. Chatbots (ChatGPT, Bard), Bildgeneratoren (MidJourney) oder Audiogeneratoren (VALL-E) (Hadi u. a. 2023, S. 3). LLMs sind ebenfalls als eine Art GenAI zu verstehen, die speziell darauf ausgerichtet sind, menschenähnliche Texte als Antwort auf einen Prompt zu generieren. Die mittlerweile breite Akzeptanz von GenAI wird aufgrund der Verfügbarkeit von FMs bestärkt. Mit der Veröffentlichung von ChatGPT, welcher eine Chat-Schnittstelle für ein leistungsfähiges LLM darstellt, durch OpenAI im November 2022, wuchs das öffentliche Interesse an GenAI zudem dramatisch an (Dolata/Lange/Schwabe 2024, S. 2).

**Anhang 7: Generative-Pre-trained-Transformers**

Die GPTs sind eine Klasse auf neuronalen Netzwerken basierenden Modellen, die die Transformer-Architektur anwenden und sich insbesondere für NLP-Aufgaben eignen (Hadi u. a. 2023, S. 4; Amazon Web Services, Inc. o. J.). Die eingesetzten DL-Modelle werden auf massiven Textdatenkorpora vortrainiert und erlauben eine anschließende Feinabstimmung für spezifische Aufgaben wie die Textklassifizierung oder Sentiment-Analyse. Die GPTs markieren einen maßgeblichen Durchbruch in der KI, insbesondere im NLP-Bereich (Yenduri u. a. 2023, S. 2). Sie ermöglichen die Existenz generativer KI-Systeme wie ChatGPT, wobei sie die Beantwortung von Fragen in Form einer Konversation oder die Erstellung menschenähnlicher Inhalte erlauben. Dies geschieht, indem GPTs Anfragen in natürlicher Sprache, d. h. Prompts, analysieren, um die wahrscheinlichste Antwort basierend auf ihrem Sprachverständnis vorzusagen. Dabei greifen sie auf ihr Wissen zu, das sie nach dem Training mit Sprachdatensätzen, bestehend aus Hunderten von Milliarden an Parametern, erworben haben. Somit berücksichtigen GPTs den Kontext von Anfragen und reagieren flexibel auf deren unterschiedliche Angaben, wodurch sie im Stande sind, lange, zusammenhängende Ausgaben zu generieren. Die GPTs werden für die Automatisierung und Optimierung einer Reihe an Aufgaben verwendet, wobei ihr Wert in ihrer Geschwindigkeit und ihrem Umfang liegt (Amazon Web Services, Inc. o. J.).

## Anhang 8: Entwicklung von ChatGPT

Im Jahr 2018 veröffentlichte OpenAI die erste Version ihres Generative-Pre-trained-Transformer-Modells (GPT), ein Large-Language-Modell (LLM) für die natürliche Sprachverarbeitung. Bereits zum damaligen Zeitpunkt bewies GPT einen hohen Leistungsgrad in einer weitreichenden Vielfalt an komplexen Sprachaufgaben. Das Modell wurde als ernsthafter Konkurrent für ähnliche KI-Modelle wahrgenommen, darunter BERT (Devlin u. a. 2019), welches Google im selben Jahr herausbrachte. Die Entwicklung und der Erfolg von GPT fußen auf bedeutenden Fortschritten im Bereich des Natural-Language-Processing (NLP), indem neue Anwendungen ermöglicht wurden, u. a. die maschinelle Übersetzung (Ranathunga u. a. 2021, S. 1–37; Bahdanau/Cho/Bengio 2016) sowie die Erstellung von Zusammenfassungen (El-Kassas u. a. 2021; Liu/Lapata 2019). Je weiter die Modelle wuchsen, desto teurer und zeitaufwändiger erwies sich das Modelltraining, da sich die Anwendungen erheblich auf umfangreich annotierten Daten stützten. Zudem erwies sich die Generalisierung auf weitere Aufgabenfelder als Herausforderung, trotz hoher Leistungsfähigkeit. Zwar waren diese NLP-Modelle Experten in ihrem beschränkten Fachgebiet, jedoch konnten sie nicht dieselbe menschliche Vielseitigkeit bei der Ausführung verschiedener Aufgaben demonstrieren. Dementsprechend entstand ein Bedürfnis für eine Methodik, dessen Training nicht auf gelabelten Daten beruht und gleichzeitig eine hohe Generalisierungsfähigkeit für verschiedene Aufgaben beherrscht. Dieser Umstand ist als die verantwortliche Kraft hinter OpenAIs Entwicklung von GPT-1 zu sehen. GPT-1 besitzt die vorteilhafte Fähigkeit, beim Modelltraining nicht auf einen großen Satz an annotierten Daten angewiesen zu sein. Das Training findet stattdessen in einem zweistufigen Prozess statt. Zunächst erfolgt das unbeaufsichtigte Vortraining (Unsupervised-Pre-training), basierend auf reichhaltigem Textmaterial und abschließend die überwachte Feinabstimmung (Supervised-Fine-Tuning), die eng mit den Endanwendungen verknüpft ist. Das Ziel des Pre-Training-Prozesses besteht darin, auf Grundlage der vorangegangenen Wörter das nachfolgende Wort eines Satzes zu prognostizieren. Somit erfordert der Ansatz des unüberwachten Lernens (Unsupervised-Learning) lediglich rohes, dennoch umfassendes Textmaterial. Nach Abschluss des Vortrainings beginnt die Phase der Feinabstimmung, die sich auf ein spezifisches Problem konzentriert, wie beispielsweise die Sentiment-Analyse. Diese Phase zeichnet sich durch einen wesentlich kleineren Satz an Daten aus als in der vorherigen. Dieser Prozess ermöglicht, dass Nutzer von GPT-1 für die Anwendung in verschiedenen Aufgabenfelder nur das Eingabeformat anpassen müssen, um die Feinabstimmung zu erleichtern. Somit ist GPT durch den Einsatz dieser beide Prozessen nicht mehr auf einen umfangreichen, markierten Datensatz angewiesen. Zugleich besteht die Fähigkeit zur Generali-

sierung über eine Vielzahl an Aufgaben hinweg fort, bei angemessenen Kosten für die Feinabstimmung. Zwar verringerte GPT-1 deutlich die Abhängigkeit von gelabelten Daten für das Training, dennoch erforderte die Feinabstimmung weiterhin eine Annotation. Um diese Abhängigkeit zu verringern und die Generalisierungsfähigkeit des Modells zu verbessern, wurde im Jahr 2019 GPT-2 eingeführt (Radford u. a. 2019). Das wesentliche Konzept des neuen Modells zeichnete sich durch eine vollständige Umstellung vom überwachten Lernen auf das unüberwachte Lernen aus. GPT-2 ist im Kern konzipiert, sein umfassendes vortrainiertes Wissen zu nutzen, basierend auf einem reichhaltigen Datenmaterial, um komplexe Aufgaben zu bewältigen. Für die Zielerreichung dessen blieb zwar die Architektur von GPT-2 gegenüber GPT-1 weitgehend unverändert, jedoch umfassten die signifikantesten Verbesserungen die Erhöhung der Datensatzgröße sowie die Anzahl an Schichten. Diese Änderungen sollten das Modell mit dem nötigen Wissen ausstatten, um eine Bandbreite an Problemen zu lösen. Die Fortschritte von GPT-1 zu GPT-2 unterstrichen „das Potenzial zur Verbesserung der Generalisierungsfähigkeit großer Sprachmodelle durch die Vergrößerung der Modellparameter und des Trainingsdatensatzes.“ (Wu/Duan/Ni 2023, S. 3) Auf diesem Wissen aufbauend, wurde GPT-3 im Jahr 2020 veröffentlicht und erwies sich als ein deutlich leistungsfähigeres Sprachmodell. Ausgestattet mit der damalig höchsten Anzahl an Parametern sowie einem umfassendem Trainingsdatensatz, erzielte GPT-3 eine bemerkenswerte Leistung in zahlreichen NLP-Aufgaben. Zudem zeichnete sich GPT-3 durch ein neuartiges Trainingsparadigma aus, nämlich das In-Kontext-Lernen (In-Context-Learning). Üblicherweise werden im konventionellen Ansatz die Ausgaben ausschließlich auf Grundlage von Anfragen prognostiziert. Gegenätzlich dazu wurde GPT-3 so trainiert, dass es die Ergebnisse vorhersagt, indem es die Anfragen sowie ihre entsprechenden Beispiele berücksichtigt. Die Fülle des Trainingsdatensatzes und die Einbeziehung von kontextbezogenen Beispielen erlaubten es GPT-3, einen hohen Informationsgehalt aus Texten zu gewinnen und verbesserten seine Fähigkeit zur Generalisierung, sodass es sich in einigen NLP-Aufgaben mit der Leistung von Menschen messen konnte. Es ist zu beobachten, dass die zunehmende Leistungsfähigkeit der GPT-Serienmodelle mit einer exponentiellen Zunahme an Parametern in Verbindung steht. Erst drei Jahre nach der Entwicklung von GPT-1, wurde das Modell weltweit zu einem der größten seiner Art erkoren, basierend auf einem Training, das 285k CPUs, 10k GPUs sowie 12 Millionen Dollar an Investitionen erforderte. Dennoch kann GPT-3 nicht als „intelligent“ bezeichnet werden und wurde, trotz seiner Komplexität an Parametern und umfangreichen Trainingsdaten, von kleineren Modellen in bestimmten Aufgaben übertroffen. Eine Erklärung für diese Divergenz bestand darin, dass GPT-3 sich während des Trainings zwar ein hohes Grundwissen aneignete, jedoch



weiterhin Schwierigkeiten aufwies, die Nutzeranfragen präzise zu verstehen sowie angemessene Antworten zu liefern. OpenAI erkannte den Verbesserungsbedarf für eine Steigerung der Reaktionsfähigkeit auf Anweisungen sowie der Denkfähigkeit des Modells und optimierten diese, indem sie das codebasierte Training und die Instruktionsabstimmung (Instruction-Tuning) einführten. Die aktualisierte Version von GPT-3 unterschied sich durch vernünftigeren Antworten auf Anfragen, die komplexes logisches Denken benötigen und durch eine gesteigerte Fähigkeit zur Generalisierung, selbst bei unbekanntem Aufgaben. Um den Abgleich zwischen menschlichem Allgemeinwissen und maschinell generierten Antworten zu verfeinern, nutzte OpenAI die Methode des Reinforcement-Learning-from-Human-Feedback (RLHF). Dieser Schritt führte zur Entwicklung von ChatGPT, welches mit seiner Veröffentlichung am 30. November 2022 rasant eine hohe Popularität und großes Interesse weltweit gewann (Wu/Duan/Ni 2023, S. 3). Am 14. März 2023, lediglich vier Monate nach dem Start von ChatGPT, stellte OpenAI sein neuestes Modell vor, GPT-4 (OpenAI 2023). Im Vergleich zu seinem Vorgänger zeichnet sich GPT-4 durch eine Vielzahl an erweiterten Generalisierungsfähigkeiten aus (Wu/Duan/Ni 2023, S. 3). Wird ChatGPT aufgefordert, sich selbst zu beschreiben, entgegnet das Sprachmodell folgendes:

*„Ich bin ChatGPT, ein fortschrittliches KI-Sprachmodell, entwickelt von OpenAI. Ich wurde erstellt, um menschenähnliche Textantworten auf eine Vielzahl von Fragen und Themen zu liefern. Mein Zweck besteht darin, Informationen bereitzustellen, komplexe Konzepte zu erklären, Ratschläge zu geben und in vielen anderen Bereichen zu helfen, in denen textbasierte Kommunikation erforderlich ist. Obwohl ich künstlich intelligent bin, habe ich keine eigenen Gedanken, Emotionen oder Überzeugungen. Stattdessen basieren meine Antworten auf den Daten, mit denen ich trainiert wurde.“* (ChatGPT 2024a)

## **Anhang 9: OpenAI**

OpenAI ist ein Forschungsunternehmen, mit Sitz in San Francisco, das seinen Fokus auf die Entwicklung von KI setzt. Gegründet im Dezember 2015 (Fitria 2023, S. 45), etablierte sich OpenAI rasch zu einem der mittlerweile führenden Akteure in der Landschaft der KI-Forschung (Mhlanga 2023, S. 6). Zu den Gründern zählen namhafte Persönlichkeiten aus der Technologiebranche, darunter Elon Musk, Peter Thiel, Greg Brockman und Sam Altman, während letzterer derzeit die Position des Chief Executive Officer von OpenAI innehält (Mhlanga 2023, S. 5). Den Hintergrund für die Gründung des Unternehmens bilden die Sorgen der Gründer um die potenzielle Gefahr bei Missbrauch und Unachtsamkeit von KI. Dementsprechend liegt ein Augenmerk des Unternehmens darauf, sichere und nützliche KI zur Verfügung zu stellen. Beispielsweise wird bei der Forschung an generativen Modellen berücksichtigt, diese mit menschlichen Werten in Einklang zu bringen, sodass KI im Sinne menschlicher Interessen entwickelt werden. Die langfristigen Ziele von OpenAI gründen sich zudem in grundlegenden Fortschritten sowie Fähigkeiten der KI selbst (Fitria 2023, S. 46). Somit setzt sich OpenAI als Mission, die Sicherstellung sowie Förderung von künstlicher allgemeiner Intelligenz (AGI), die der gesamten Menschheit zugutekommen soll (OpenAI o. J.a). Im Jahr 2019 wurde OpenAI zu einem gewinnorientierten Unternehmen, nachdem es als eine Non-Profit-Organisation (NPO) ins Leben gerufen wurde (Mhlanga 2023, S. 5). OpenAI pflegt zahlreiche Partnerschaften, u.a. mit Microsoft, welches im Zuge der finanziellen Transformation von OpenAI hohe Investitionen in das Unternehmen getätigt hat (OpenAI o. J.b). Strukturell verbleibt OpenAI jedoch in einer Partnerschaft aus ihrer ursprünglichen NPO und ihrem kommerziellen Zweig. Die positive Absicht für den Start von OpenAI spiegeln sich damit weiterhin im Arbeitssystem als auch in den Produkten des Unternehmens wider (Fitria 2023, S. 46), indem das Unternehmen fortwährend einen hohen Fokus auf ethische Aspekte in der Entwicklung von KI legt (OpenAI o. J.c). Zu den bekanntesten Produkten von OpenAI zählen die GPT-Serie, darunter ChatGPT, sowie DALL-E (Fitria 2023, S. 45).

## **Anhang 10: Anwendungsgebiete von ChatGPT in der der Marktforschung nach ChatGPT**

Wird ChatGPT gefragt, wie es die Marktforschung unterstützen kann, bietet das Sprachmodelle folgende Einsatzpotenziale:

„ChatGPT kann die Marktforschungspraxis in beiden Bereichen, der quantitativen und qualitativen Marktforschung, unterstützen:

### 1. Quantitative Marktforschung:

- Datenerfassung und -analyse: ChatGPT kann in Umfragen und Befragungen eingesetzt werden, um große Mengen strukturierter Daten schnell zu sammeln und zu analysieren.

- Trendanalyse: Durch die Analyse von großen Datensätzen aus sozialen Medien, Online-Foren und anderen Quellen kann ChatGPT helfen, Trends und Muster in Verhalten und Vorlieben von Verbrauchern zu identifizieren.

- Prognosen: ChatGPT kann bei der Erstellung von Prognosen und Vorhersagen für Umsatzentwicklungen, Marktgröße und andere Kennzahlen helfen, indem es historische Daten analysiert und Trends extrapolieren kann.

### 2. Qualitative Marktforschung:

- Verbraucherfeedback: ChatGPT kann genutzt werden, um Verbraucherfeedback in natürlicher Sprache zu sammeln und zu interpretieren, indem es auf offene Fragen antwortet und Stimmungsanalysen durchführt.

- Tiefere Einblicke: Durch die Durchführung von Interviews oder Fokusgruppen kann ChatGPT qualitative Daten sammeln, die helfen, tiefergehende Einblicke in die Bedürfnisse, Einstellungen und Wahrnehmungen von Verbrauchern zu gewinnen.

- Markenwahrnehmung: ChatGPT kann verwendet werden, um die Wahrnehmung einer Marke oder eines Produkts durch Verbraucher zu erforschen, indem es deren Meinungen und Gefühle in natürlicher Sprache analysiert.

In beiden Bereichen kann ChatGPT dazu beitragen, den Forschungsprozess zu beschleunigen, Kosten zu senken und neue Erkenntnisse zu gewinnen, indem es menschenähnliche Interaktionen ermöglicht und eine Vielzahl von Datenquellen analysiert.“ (ChatGPT 2024c)

## Anhang 11: Weitere Prompt-Engineering-Strategien

Im Folgenden werden weitere Strategien für das Prompt-Engineering (PE) innerhalb OpenAIs Application Programming Interface (API) betrachtet, die in der Regel die Zuverlässigkeit der Ausgaben garantieren und von OpenAI selbst für ihre Modelle empfohlen werden (OpenAI o. J.e).

*Verwendung externer Werkzeuge:* Um die Grenzen des Modells zu überwinden und seine Schwächen auszugleichen, empfiehlt sich die Zuhilfenahme externer Werkzeuge. Durch die Delegation von Aufgaben an externe Tools, die dafür angemessener geeignet sind, werden die Effizienz und die Zuverlässigkeit des LLM gesteigert. Beispielsweise ermöglicht die Implementierung einer eingebetteten Suchfunktion eine effizientere Wissensbeschaffung. Fließen externe Informationen in die Eingabe ein, kann die KI diese nutzen und damit die Aktualität sowie Qualität der Ergebnisse sicherstellen. Darüber hinaus kann die Verwendung von Texteinbettungen die effiziente Wissensabfrage erleichtern, indem relevante Informationen in der Eingabe dynamisch während der Laufzeit erweitert werden (OpenAI o. J.e).

*Veränderungen in den Antworten systematisch testen:* Um den Prozess der Optimierung der Leistungsfähigkeit des LLM zu erleichtern, ist eine effektive Messung essenziell. In einzelnen Fällen kann zwar die Änderung von Prompts die Leistung verbessern, allerdings im Gegenzug die Gesamtleistung in einer repräsentativen Gruppe von Beispielen verringern. Für die Gewährleistung einer positiven Nettoveränderung der Leistung ist daher die Definition einer umfassenden Testreihe ratsam. Dies geschieht über Evaluierungsverfahren, sogenannte „evals“, die bei der Optimierung von Systementwürfen von entscheidender Bedeutung sind. Hierbei zeichnen sich wirksame Evaluierungen dadurch aus, indem sie mühelos zu wiederholen und automatisieren sind, die reale Nutzung abbilden sowie zahlreiche Testfälle für eine robuste statistische Analyse enthalten. Der Einsatz von modellbasierten Evaluierungen erweist sich als vorteilhaft für Szenarien, in denen ein Spektrum potenzieller Ergebnisse von gleichermaßen hoher Qualität angesehen werden, wie z. B. bei Fragen mit umfangreichen Antworten. Es ist zu beachten, dass die Grenze zwischen dem, was eine humanbasierte Evaluierung erfordert und dem, was realistisch über eine modellbasierte Evaluierung bewertet werden kann, unscharf ist und sich mit den Fortschritten in den Modellfähigkeiten weiter verschiebt. Somit ist weiterhin Experimentierfreudigkeit für die Ermittlung, wie gut sich die modellbasierten Evaluierungen für den jeweiligen Anwendungsfall eignen, gefragt (OpenAI o. J.e).

## Anhang 12: Large-Language-Model-Einstellungen

*Modell:* Es wird geraten, das neueste Modell zu verwenden, da es in der Regel eine gesteigerte Leistungsfähigkeit demonstriert, im Gegenzug jedoch höhere Kosten sowie eine höhere Latenz aufweist (OpenAI o. J.d). Außerdem ist die Variation der Ausgaben, je nach Version des LLM, zu beachten (Saravia o. J.b).

*Temperatur (Temperature):* Der Parameter Temperatur steuert, wie zufällig die Ausgaben des KI-Modells sind und beeinflusst im Wesentlichen die Gewichtung der übrigen potenziellen Token. Eine niedrige Temperatureinstellung bewirkt deterministischere Ausgaben, d. h., dass immer das wahrscheinlichste nächste Token ausgewählt wird, während eine höhere Temperatur zu mehr Zufälligkeit führt. Dadurch werden kreativere oder vielfältigere Ergebnisse begünstigt, indem das Gewicht der anderen potenziellen Tokens erhöht wird. Beispielsweise empfiehlt es sich, für die Datenannotation eine niedrige Temperatur, wie 0, einzustellen, um präzise Ausgaben zu fördern (Törnberg 2024, S. 13; Saravia o. J.b).

*Top P:* Top P, auch als Nucleus Sampling bekannt, bezeichnet eine Stichprobentechnik mit Temperatur, die beeinflusst, wie deterministisch das Modell vorgehen soll. Die Verwendung von Top P bedeutet, dass nur diejenigen Tokens beachtet werden, „die die top\_p Wahrscheinlichkeitsmasse bilden“ (Saravia o. J.b). Ein niedriger top\_p-Wert wählt die selbstsicherste Antwort aus, sodass dies die empfohlene Einstellung für exakte und faktische Ausgaben ist. Dagegen erlaubt ein hoher top\_p-Wert dem Modell, mehr mögliche Token zu berücksichtigen, auch unwahrscheinlichere, wodurch es zu vielfältigeren Antworten kommt (Törnberg 2024, S. 13).

Generell empfiehlt es sich, entweder nur Top P oder nur die Temperatur zu ändern (Saravia o. J.b).

*Maximale Länge (Max-Length):* Dieser Parameter legt die maximale Anzahl von Token fest, die das Modell generieren soll. Durch die Reduzierung der Ausgabe auf eine maximale Länge werden Kosten kontrolliert und lange oder irrelevante Antworten vermieden (Törnberg 2024, S. 12; Saravia o. J.b).

*Stopp-Sequenz (Stop-Sequence):* Mit „Stop-Sequence“ wird eine Zeichenfolge bezeichnet, die das Modell bremst, weitere Token auszugeben. Damit bietet die Nutzung von Stopp-Sequenzen eine weitere Möglichkeit, die Struktur sowie die Länge der Antworten zu steuern (Saravia o. J.b).

*Frequenzstrafe (Frequency-Penalty):* „Frequency-Penalty“, auch als Häufigkeitsstrafe bekannt, bestraft das nächste Token, indem die Strafe proportional zur Häufigkeit steht, mit der dieses Token bereits im Prompt und in der Antwort aufgetreten ist. Je höher die Frequenzstrafe ausfällt, desto unwahrscheinlicher wird ein Token erneut auftauchen, sodass diese Einstellung die Wiederholung von Wörtern reduziert (Saravia o. J.b).

*Anwesenheitsstrafe (Presence-Penalty):* Die Anwesenheitsstrafe bedient sich ebenfalls einer Strafe auf wiederkehrenden Token an, jedoch ist die Strafe im Gegensatz zur Frequenzstrafe für alle wiederholten Wörter dieselbe. Dementsprechend wird ein Token, das zweimal auftritt, genauso hart bestraft wie ein Token, das zehnmal erscheint. Mithilfe der Anwesenheitsstrafe wird vermieden, dass das Sprachmodell Phrasen zu häufig in seinen Ausgaben wiederholt. Für eine kreativere oder vielfältigere Textgenerierung empfiehlt sich eine höhere Einstellung, während für fokussierte Antworten eine niedrigere Anwesenheitsstrafe zu gebrauchen ist.

Vergleichbar mit „top\_p“ und „temperature“, sollten entweder nur die Anwesenheitsstrafe oder die Frequenzstrafe verändert werden (Saravia o. J.b).

### Anhang 13: Prompt-Engineering vs. Fine-Tuning

Das Fine-Tuning, auf Deutsch Feinabstimmung, wird häufig im Kontext des Prompt-Engineering (PE) erwähnt. Beide Ansätze sind eng miteinander verbunden, dennoch bezeichnen sie zwei unterschiedliche Methoden, die dasselbe Ziel verfolgen: die Nutzung der Fähigkeiten von LLMs zur Bewältigung spezifischer Aufgaben und somit die Optimierung der Relevanz und Genauigkeit der Ausgaben (Junco 2023). Das Fine-Tuning bezeichnet eine Transfer-Lernmethode, die darauf ausgerichtet ist, dass in vortrainierten neuronalen Netzen eingebettete Wissen zu nutzen, um neue Aufgaben zu lösen. Im Kontext des NLP findet das Fine-Tuning seinen Einsatz in der Anpassung von großen, vortrainierten Sprachmodellen (Large-Pre-trained-Language-Models), z. B. GPT-3.5 oder GPT-4, an spezifische Aufgaben wie die Sentiment-Analyse oder die Textklassifikation. Die Nutzung des im vortrainierten Modell enthaltenen Wissens erlaubt es dem Fine-Tuning, die Generalisierungs-Fähigkeit des Modells für neue Aufgaben erheblich zu verbessern. Das Fine-Tuning birgt das Potenzial, die Effizienz des Modells bei der Bewältigung neuer Aufgaben zu verbessern sowie gleichzeitig die Trainingsdauer deutlich zu verkürzen, wobei das Fine-Tuning die Aktualisierung aller Modellparameter umfasst (Zheng u. a. 2023, S. 3–4; Junco 2023). Zwar kann Fine-Tuning die Kompatibilität von Modellen wie ChatGPT für bestimmte Anwendungen optimieren, doch erfordert dies eine sorgfältige Planung und ist mit einem gewissen Arbeitsaufwand verbunden. OpenAI empfiehlt für seine Modelle zunächst mit PE zu experimentieren, um die gewünschten Ergebnisse zu erzielen, bevor sich dem Fine-Tuning zugewandt wird. Im Regelfall sind mit effizienten Prompts, Aufgaben zu bewältigen, bei denen das Modell initial nicht gut abschnitt, sodass ein Fine-Tuning nicht erforderlich ist. Zudem bietet die Iteration über Prompts den Vorteil einer schnelleren Rückkopplungsschleife, im Gegensatz zur Iteration mit Fine-Tuning, das auf die Zusammenstellung von Datensätzen und die Ausführung von Trainingsaufgaben angewiesen ist. In den Szenarien, in denen das Fine-Tuning unvermeidlich ist, rentiert sich die vorherige PE-Arbeit weiterhin, da in der Regel die relevantesten Ergebnisse zu beobachten sind, wenn geschickte Prompts in den Fine-Tuning-Daten eingesetzt werden. Somit lassen sich beide Ansätze für eine optimierte Leistung des LLM miteinander kombinieren (OpenAI o. J.e).

## Anhang 14: Prompthaton

Das ITZ Plus Biberach beschreibt die Workshop-Veranstaltung „Prompthaton“ folgendermaßen:

*„Ein Prompthaton ist ein Event, bei dem Teilnehmer aus verschiedenen Bereichen lernen und praktizieren, wie man KI-Systeme wie GPT mittels spezifischer Anfragen oder "Prompts" für kreative und geschäftliche Zwecke nutzt. Die Teilnehmer experimentieren in Workshops und Gruppenarbeiten, um innovative Ideen und Lösungen zu entwickeln, wobei der Schwerpunkt auf der praktischen Anwendung von KI in der Geschäftswelt liegt. Der Prompthaton fördert somit Innovation, Kreativität und den Austausch von Erfahrungen. den Teilnehmern. Ziel ist es, neue Perspektiven zu eröffnen und konkrete Lösungsansätze für die Herausforderungen und Chancen in der modernen Geschäftswelt zu entwickeln.“ (ITZ Plus Biberach 2024)*

Im Folgenden werden die Erkenntnisse, die aus den Vorträgen, Workshops und der abschließenden Feedbackrunde entstammen, zusammengefasst dargelegt. Hierfür wurde die Zustimmung des Veranstalters eingeholt.

Im ersten, einführenden Part des Prompthaton betonen die Experten, dass der Einsatz von KI disruptive Auswirkungen auf die Arbeitswelt ausübt. KIs bergen das Potenzial, die zumeist ineffiziente Wertschöpfung in Unternehmen, wie die Verschwendung zeitlicher Ressourcen im Büro, aufzubrechen. Trotz der vielversprechenden Perspektiven, die der Einsatz von KI bietet, ist ein kritischer Faktor der hohe Nachholbedarf im Bereich der Digitalisierung in Deutschland. Dementsprechend gilt es branchenübergreifend, digitale Prozesse zu optimieren. Die Experten unterstreichen, dass ohne einen grundlegenden Willen zur Digitalisierung und eine fehlende Infrastruktur, KIs nicht in vollem Maße in Unternehmen eingesetzt werden können. Dabei ist es von hoher Bedeutung zu verstehen, was Nutzer von KIs tatsächlich erwarten können. Beispielsweise ist ChatGPT kein allmächtiges KI-Modell, wie es vielfach dargestellt wird, sondern es ist im Wesentlichen ein statistisches Sprachmodell, das die Wahrscheinlichkeit des nächsten Wortes berechnet und folglich kein eigenes Bewusstsein aufweist. Außerdem sollten sich Anwender der Risiken und Grenzen von KI-Modellen bewusst sein, wie z.B. die geringe Nachvollzieh- sowie Prognostizierbarkeit oder die Möglichkeit zum Missbrauch. Die Experten weisen darauf hin, dass KIs derzeit nicht eigenständig ohne die menschliche Anleitung und das entsprechende Fachwissen agieren können. Somit werden in voraussehbarer Zeit nicht KIs den Menschen ersetzen, sondern vielmehr werden Menschen ohne KI-Expertise durch Menschen mit KI-Expertise abgelöst.



Im zweiten Teil der Veranstaltung wurden die Prompt-Grundlagen präsentiert. Diese dienen als erster Einstieg in den Bereich des Prompt-Engineering (PE) und vereinen einige der zuvor ausgeführten Prompt-Techniken. Hierbei sagen die Experten aus, dass ein vertieftes Wissen zu PE nicht zwingend erforderlich ist für jede Aufgabe. Oftmals werden solide Ergebnisse durch die Anwendung von einfachen Prompt-Grundlagen erreicht, wobei unzureichende Ausgaben in der Regel auf schlechte Prompts zurückzuführen sind. Die vorgestellten Prompt-Grundlagen sind wie folgt:

*Handle als <Rollenname>:* Mithilfe von Role-Prompting, nimmt ChatGPT eine Rolle mit deren entsprechenden Eigenschaften und Fachwissen ein und wird somit befähigt, eine spezifische Aufgabe zu lösen.

*Ich werde dir <Infos> zur Verfügung stellen:* Indem der Kontext und weitere Referenztexte bereitgestellt werden, wird eine höhere Relevanz der Ergebnisse gewährleistet.

*Und du wirst <detaillierte Aufgabe schildern>:* Es empfiehlt sich den Arbeitsablauf zu detaillieren, um ChatGPT eine Orientierung zu bieten.

*Dies beinhaltet <konkrete Ergebnisse ausführen>:* Die Beschreibung des Ausgabeformats lenkt ChatGPT in die gewünschte Richtung.

Weiterhin ist es ratsam, die Zielgruppe auszuführen, um die Ausgaben an diese maßzuschneidern bzw. eine höhere Relevanz der Ergebnisse zu erreichen. Zudem ist eine weitere empfohlene Prompting-Strategie, sich bei ChatGPT zu erkundigen, ob es weitere Fragen zur Aufgabe hat, falls Unklarheiten bestehen. Somit soll sichergestellt werden, dass ChatGPT alle benötigten Informationen für die Ausführung der Aufgabe besitzt.

Die Prompt-Grundlagen gelten hierbei branchenübergreifend und sind universell einsetzbar. Je nach Anwendungsfall empfiehlt es sich mit den verschiedenen Prompt-Techniken zu experimentieren. Darüber hinaus ist zu beachten, dass sich die Qualität der Ergebnisse zwischen den Modellen GPT-3.5, der kostenlosen Version, und GPT-4 unterscheiden, wobei das neue Modell eine höhere Ausgabe-Qualität aufweist, sodass es ratsam ist, das neuste Modell zu verwenden.

Der Prompthaton wurde mit einer Feedbackrunde abgeschlossen, in der die Teilnehmer ihre persönlichen Erfahrungen und Erkenntnisse schilderten. Insgesamt sind die Teilnehmer begeistert von den Möglichkeiten der KI-Modelle wie ChatGPT und sehen ein deutliches Potenzial zur Effizienzsteigerung sowie zur Zeit- und Kostenersparnis im Arbeitsalltag. ChatGPT

eignet sich hierbei insbesondere als Impulsgeber für Ideen in der Anfangsphase eines Projekts. Die Teilnehmenden stellten fest, dass die Formulierung des Prompts einen maßgeblichen Einfluss auf die Ergebnisse hat und reflektieren, dass sie häufig mit den Ausgaben von ChatGPT unzufrieden und frustriert waren, was zumeist auf einen schlecht formulierten Prompt zurückzuführen ist. PE kann dementsprechend zu einer positiven Nutzererfahrung beitragen, indem relevantere Ergebnisse erzielt werden. Die Teilnehmer einigen sich darauf, dass neben Kenntnissen im PE die jeweilige Fachexpertise weiterhin eine entscheidende Rolle spielt, um das Sprachmodell gezielt für die bevorstehende Aufgabe anzuleiten und die Ausgaben zu verifizieren. Die Teilnehmer haben übergreifend den Eindruck, dass ein aktiver Einsatz und ein tiefgreifendes Verständnis über Sprachmodelle sowie Kompetenzen im Bereich des PE selten in deutschen Unternehmen zu finden sind. Aus ihrer Erfahrung sprechend, sind Unternehmen nicht ausreichend an einem Schulungsangebot für Mitarbeiter interessiert, weshalb die Unwissenheit in diesem Bereich immens ist, insbesondere bei der älteren Generation. Es ist zwar Halbwissen im Umlauf, jedoch überwiegend kein konkretes Verständnis über die Wichtigkeit der Prompt-Formulierung und des Einsatzpotenzials von ChatGPT. Zudem wurde erwähnt, dass viele Unternehmen keine KI-Richtlinien bereitstellen, sodass KIs nicht angewendet werden können. Somit stehen Unternehmen in der Verantwortung, ihren Mitarbeitern eine Orientierung für den Einsatz von KIs zu bieten, um Unsicherheit zu vermeiden. Die Teilnehmer konstatieren, dass es essenziell für Unternehmen ist, eine offene Haltung gegenüber KI zu pflegen, da ein Mangel an dieser Bereitschaft rasant zu einem Rückstand führen kann. Die Teilnehmer schließen mit der Erkenntnis ab, dass im Bereich KI, aufgrund seiner fortschreitenden und dynamischen Entwicklung, ein kontinuierliches Lernen unabdingbar ist.

**Anhang 15: Leitfaden Experteninterviews****Auf Deutsch:**

- Welche Auswirkungen hat der Einsatz von Sprachmodellen wie ChatGPT auf die Marktforschung?
- Welche Rolle nimmt Prompt-Engineering in der Marktforschung ein?
- Gehen Sie davon aus, dass die Fähigkeit des Prompt-Engineerings zu einer weiteren Kompetenz für Marktforscher wird, wenn diese mit ChatGPT zusammenarbeiten möchten?
- Nehmen Sie an, dass Prompt-Engineering unerlässlich für Marktforschungsunternehmen ist, die Sprachmodelle wie ChatGPT nutzen wollen?
- Welche Vorteile bestehen darin, Prompt-Engineering in der Marktforschung einzusetzen, wenn mit einer KI wie ChatGPT zusammengearbeitet wird?
- Inwieweit wirkt sich die Formulierung der Prompts auf die Qualität der Ergebnisse aus?
- Was ist bei der Formulierung eines zielgerichteten Prompts zu beachten?
- Wie kann die Nutzung von Prompt-Engineering die Genauigkeit und die Effizienz von Marktforschungsstudien optimieren?
- Für welche spezifischen Anwendungsgebiete ist das Prompt-Engineering in der Marktforschung besonders geeignet?
- Welche Prompt-Engineering-Strategien sind für die Marktforschung besonders relevant?
- Über welche spezifischen Fähigkeiten sollten Marktforscher verfügen, um das volle Potenzial von Prompt-Engineering auszuschöpfen?
- In welchem Grad könnte der Einsatz von Künstlicher Intelligenz und insbesondere Prompt-Engineering als neue Kompetenz die bisherigen Forschungsansätze und -methoden in der Marktforschung verändern?
- In welcher Weise könnten Marktforscher zukünftig geschult werden, um effektiv mit Künstlicher Intelligenz und Prompt-Engineering umgehen zu können?
- Welches Vorgehen ist erforderlich, wenn ein Unternehmen ChatGPT implementieren und Prompt-Engineering anwenden möchte?
- Glauben Sie, dass Prompt-Engineering auch in Zukunft eine relevante Kompetenz bleiben wird, oder gehen Sie davon aus, dass Fortschritte der Künstlichen Intelligenz Prompt-Engineering überflüssig machen werden?

**Auf Englisch:**

- What impact does the use of language models such as ChatGPT have on market research?
- What role does prompt engineering play in market research?
- Do you assume that the ability to prompt-engineer will become another competency for market researchers if they want to work with ChatGPT?
- Do you assume that prompt engineering is essential for market research companies that want to use language models like ChatGPT?
- What are the benefits of using prompt engineering in market research when working with an AI like ChatGPT?
- To what extent does the formulation of the prompts affect the quality of the results?
- What needs to be considered when formulating a targeted prompt?
- How can the use of prompt engineering optimise the accuracy and efficiency of market research studies?
- For which specific areas of application is prompt engineering particularly suitable in market research?
- Which prompt engineering strategies are particularly relevant for market research?
- What specific skills should market researchers have in order to utilise the full potential of prompt engineering?
- To what extent could the use of artificial intelligence and, in particular, prompt engineering as a new competence change existing research approaches and methods in market research?
- How could market researchers be trained in the future to be able to deal effectively with artificial intelligence and prompt engineering?
- What approach is required if an organisation wants to implement ChatGPT and use prompt engineering?
- Do you think that prompt engineering will remain a relevant skill in the future, or do you think that advances in artificial intelligence will make prompt engineering redundant?

## **Anhang 16: Zusätzliche Untersuchungsfelder aus der empirischen Forschung**

### ***Welche Auswirkungen hat der Einsatz von Sprachmodellen wie ChatGPT auf die Marktforschung?***

Es herrscht ein mehrheitlicher Konsens, dass der Einsatz von KI-Modellen wie ChatGPT einen bedeutenden Einfluss auf die Marktforschung (Mafo) sowie im weiteren Sinne auf sämtliche Wirtschaftsbereiche ausübt. Hierbei ist eine disruptive Auswirkung auf die Arbeitswelt zu erwarten, indem die zumeist ineffiziente Wertschöpfung in Unternehmen durch KI aufgebrochen würde (Prompthaton). Der Prompthaton und die Mehrheit der Experten kritisieren hierbei, dass Deutschland einen Innovationsrückstand bei der Nutzung von KI aufweist. Ebenfalls bemängeln sie, dass das Bewusstsein für KI und das Ausmaß ihrer Nutzung in den Mafo-Unternehmen stark variieren. Nichtsdestotrotz beobachtet Experte 4 einen wachsenden Trend der Anwendung von ChatGPT und weiteren KI in der Mafo. Der Prompthaton und Experte 2 notieren, dass ChatGPT, trotz seines Potenzials als Hilfswerkzeug, kritisch in seinen Ergebnissen zu hinterfragen ist. Im Folgenden werden die Nutzungspotenziale von ChatGPT aufgelistet, die laut den Experten den zunehmenden Einsatz des Modells begründen.

Experte 1 sagt aus, dass ChatGPT die Möglichkeit zur Automatisierung des Forschungsprozesses bietet, indem es die Durchführung der Forschung erleichtern kann und bei der Nachbereitung behilflich zeigen kann. Die Experten 2, 6, 7 und 9 heben ChatGPTs Potenzial zur schnellen Analyse großer Datenmengen hervor, was laut Experte 2 zu einer raschen Informationsbeschaffung führt. Da sich Sprachmodelle auf Informationen stützen, könnte mithilfe dieser Technologie die Fülle an Kundeninformationen für Unternehmen alltäglich nutzbar bereitgestellt werden. Dies bedeute neue Anforderungen an die Marktforscher, denn es sei essenziell, die Funktionsweise der KI zu verstehen, insbesondere wie die KI mit den eingespeisten Daten arbeitet (9). Die Experten 6 und 7 merken zudem die Möglichkeit der Automatisierung der Datenanalyse an, wodurch die Produktivität der Forscher signifikant steigen kann. ChatGPT kann den Bereich der Advanced-Data-Analytics vorantreiben und z. B. die Durchführung komplexer Regressionsanalysen erleichtern. Da das Modell in natürlicher Sprache operiert, sind Programmierkenntnisse nicht vonnöten, wodurch sich diese Methoden auch für fachfremde Personen eröffnen (7). Experte 7 verweist darauf, dass ChatGPT Einschränkungen aufweisen kann, falls die Daten nicht im notwendigen Format vorhanden sind. Jedoch seien in diesem Feld signifikante Fortschritte zu erwarten. Die Experten 2, 3 und 5 bemerken, dass sich ChatGPT für eine schnelle und unkomplizierte Informationsbeschaffung eignet. Sie betrachten ChatGPT als Werkzeug, um sich einen ersten Eindruck über ein Thema,

z. B. über ein Marktsegment, zu verschaffen, insbesondere wenn geringes Vorwissen besteht. Dies sei nur unter Voraussetzung von geeignetem Prompting möglich (3). Durch ChatGPT rücke hierbei die manuelle und meist zeitintensive Suchmaschinenrecherche in den Hintergrund (5). In Mafo-Unternehmen ließe sich ChatGPT in der Anfangsphase verwenden, um etwa eine anfängliche Strukturierung des Themas zu erhalten (5). Nichtsdestotrotz weisen die drei Experten auf Risiken für die Nutzung von ChatGPT als Informationsbereitsteller hin. Expertin 3 und Experte 5 führen aus, dass die gewonnenen Informationen auf die Plausibilität und Belastbarkeit der Quellen hin geprüft werden sollen, da ChatGPT halluzinieren kann. Experte 8 sieht ChatGPTs Einsatzgebiet in diversen Teilaufgaben der Mafo, wie der Codierung offener Nennungen. Jedoch bestehen Schwierigkeiten, ChatGPT in das Projektgeschäft zu implementieren. Dies sei insbesondere für das Qualitätsmanagement relevant, das eine gewisse Stabilität der Ergebnisse erfordere, die ChatGPT durch die tendenzielle Variabilität seiner Ausgaben nicht erfüllen könne. Für den Experten 8 ist es ein entscheidendes Kriterium, Standardisierung und Skalierbarkeit im Ergebnisprozess zu erreichen. Das Mafo-Unternehmen des Experten 8 verwendet die KI betriebsintern, indem ein geschlossener ChatGPT-Assistent, der zukünftig als Wissensdatenbank fungieren soll, entwickelt wird. Der Aufbau einer KI-gestützten Wissensbasis würde laut dem Experten 8 rasch Einzug in die Industrie finden, wobei dies unabhängig von der Mafo sei. Die Experten 5 und 8 betonen, dass Mafo-Unternehmen gründlich untersuchen sollten, in welchen konkreten Anwendungsfällen sich die Nutzung von ChatGPT eignet.

***Welches Vorgehen ist erforderlich, wenn ein Unternehmen ChatGPT implementieren und Prompt-Engineering anwenden möchte?***

Die Experten sind sich einig, dass ein schrittweiser Einführungsprozess mit diversen Schulungen sowie die Bereitstellung von Richtlinien, die zur Orientierung der Forscher dienen, erforderlich für die Implementierung von PE sind. In den Aussagen der Experten 1, 2, 4, 5, und 7 finden sich Gemeinsamkeiten und Ähnlichkeiten dahingehend, wie PE in einem Mafo-Unternehmen zu integrieren ist. Laut Experte 2 soll die Implementierung mit einer Bewertung der Offenheit bei der Belegschaft für die Thematik beginnen. Darauffolgend sollte ein detaillierter Plan entwickelt werden, der beinhaltet, welche Ziele mithilfe der KI erreicht werden sollen und wie jene dafür zu nutzen ist (2). Eine vergleichbare Empfehlung stammt von Experte 4. Ihm zufolge steht am Anfang die Prozessanalyse, in der eingehend zu analysieren ist, was typische Arbeitsabläufe im Unternehmen sind und wie hierbei ChatGPT und PE integriert werden können. Im nächsten Schritt würde auf Grundlage dieser Erkenntnisse eine „Road-

map“ skizziert (siehe Anhang 20), die die geeigneten Prozesse identifizieren sowie die Durchführbarkeit der Implementierung, die Ressourcenbeanspruchung, die potenziellen Auswirkungen und die Vorteile für die Forscher bewerte. Im Anschluss ist laut Experte 2 das Mafo-Unternehmen gefragt, seine Mitarbeiter intensiv zu schulen und ihnen klar zu kommunizieren, wie ChatGPT sie bei ihrer täglichen Arbeit unterstützen könnte. Zudem sollten die Marktforscher aktiv zur Nutzung der KI motiviert werden, um mögliche Berührungspunkte abzubauen. Experte 7 rät davon ab, PE mit einem Strategieprojekt einzuführen, da dies einen zu hohen Arbeitsaufwand darstellen würde; stattdessen sei eine anfängliche Festlegung von „taktischen Spielregeln“ zu bevorzugen (siehe Anhang 23). Die Experten 1 und 5 betonen ebenfalls die Relevanz der Implementierung von Richtlinien. Hierin sollten, neben der korrekten Nutzung von ChatGPT, datenschutzrechtliche Aspekte Beachtung finden (1, 5, 7). Die Experten raten dazu, sensible Daten wie Unternehmensinformationen oder Kundendaten nicht einzugeben, sondern diese zu anonymisieren oder zu pseudonymisieren (1, 5, 7). Darüber hinaus empfiehlt Experte 4, einen Leiter für den KI-Bereich im Unternehmen zu designieren, der, im Falle von Custom-GPTs, ein umfangreiches Wissen zum Training und zur Einstellung des Modells aufweist und als Experte im PE das Modell modifizieren kann. Die Experten 1 und 7 sowie der Prompthaton betonen zudem die generell nötige Integration von KI und PE, um weiterhin wettbewerbsfähig zu bleiben, sodass Unternehmen gezwungen sind, sich langfristig mit dieser Thematik zu beschäftigen. Experte 4 kritisiert ebenfalls, dass die Schritte zur Implementierung von PE identisch mit anderen Technologieeinführungen seien, jedoch würden sich viele Unternehmen scheuen, diesen Prozess zu beginnen.