HOCHSCHULE RUHR WEST

STUDIENGANG: BWL - INTERNATIONALES MARKETINGMANAGEMENT

MÜLHEIM A. D. RUHR

ABSCHLUSSARBEIT ZUR ERLANGUNG DES

AKADEMISCHEN TITELS MASTER OF ARTS (M. A.)

POTENZIALE VON KI IM SOCIAL MEDIA MANAGEMENT - ZUKUNFTSPERSPEKTIVE FÜR CARAMBA - ANPASSUNG VON CONTENT, KAMPAGNEN- UND WERBEANZEIGENMANAGEMENT

Erstprüfer:	Prof. Dr. Simone Roth
Zweitprüfer:	Simon Thomaßen
Eingereicht am:	15. November 2025

Kevin Klostermeyer

Matrikelnummer: 10011075

Inhaltsverzeichnis

Abstract ..... **IV**

Gender-Hinweis ..... **V**

Hilfsmittel ..... **V**

Abbildungsverzeichnis ..... **VI**

Tabellenverzeichnis ..... **VI**

Abkürzungsverzeichnis ..... **VII**

1 Einleitung **1**

1.1 Problemstellung und Relevanz des Themas 1

1.2 Zielsetzung der Fragestellung 2

1.3 Methodik und Konzept der Thesis 3

1.4 Aufbau der Arbeit 4

2 Theoretische Grundlagen **6**

2.1 Grundlagen des Social-Media-Managements 6

2.1.1 Definition und Aufgabenfelder 6

2.1.2 Content-Erstellung und Kampagnenmanagement 7

2.1.3 Meta-Werbeanzeigenmanagement 9

2.1.4 Herausforderungen im Social-Media-Management 11

2.2 Grundlagen der Künstlichen Intelligenz 12

2.2.1 Grundlagen und historische Entwicklung 12

2.2.2 Technologien und Anwendungen im Überblick 13

3 Aktueller Stand in Wissenschaft und Praxis **15**

3.1 Status quo der Wissenschaft: Anwendungsfelder von KI 15

3.1.1 Content-Erstellung und -Optimierung durch KI 15

3.1.2 KI-basierte Kampagnenplanung und Steuerung 16

3.1.3 Social Listening und Sentiment-Analyse durch KI 17
3.1.4 Anwendung von KI im Werbeanzeigenmanagement 19
3.2 Status quo der Praxis 20
3.2.1 Möglichkeiten der KI-Implementierung 20
3.2.2 Best-Practice-Beispiele Kraft Heinz und L'Oréal 22
3.2.3 Herausforderungen und Grenzen der KI-Implementierung 23
3.3 Caramba 26
3.3.1 Unternehmensprofil und Geschäftsmodell 26
3.3.2 Instagram - Social-Media-Audit Caramba 27
4 Empirische Analyse mithilfe von A/B-Test am Beispiel von Caramba 32
4.1 Methodisches Vorgehen zur KI-Integration 32
4.1.1 Zielsetzung des A/B-Tests im Meta-Werbeanzeigenmanager 32
4.1.2 Auswahl der KI-Tools und -Modelle 33
4.1.3 Aufbau eines Testplans 36
4.1.4 Definition relevanter KPIs 38
4.2 Praktische Anwendung und prototypische Umsetzung 40
4.2.1 Einrichtung einer Testkampagne 40
4.2.2 Automatisierte Generierung von Anzeigentexten 42
4.2.3 Zielgruppensegmentierung und Gebotsoptimierung 43
4.3 Evaluation der KI-gestützten Kampagnenleistung 45
4.3.1 Systematische Erhebung und Auswertung der Kampagnendaten 45
4.3.2 Vergleichende Analyse: KI-basiert vs. manuell gesteuert 46
4.3.3 Reflexion der Hypothese 48
5 Zukunftsperspektiven und Handlungsempfehlungen 49
5.1 Szenarien für die Integration von KI im Social-Media-Management 49

5.2 Potenziale und Chancen für Caramba 51
5.3 Risiken und Herausforderungen der Umsetzung 52
5.4 Content, Kampagnen- und Werbeanzeigenmanagement 54
6 Diskussion 56
7 Fazit und Ausblick 58
7.1 Zusammenfassung und Reflexion der Ergebnisse 58
7.2 Ausblick und weiterführender Forschungsbedarf 59
Literaturverzeichnis 62
Anhangverzeichnis 77
Anhang 79

Abstract

In der vorliegenden Arbeit wird untersucht, inwiefern Künstliche Intelligenz (KI) im Social-Media-Management unter Bedingungen hoher Plattformdynamik dazu beitragen kann, Effizienz und Steuerungsfähigkeit zu steigern, ohne dabei Authentizität und Transparenz zu beeinträchtigen. Als Fallbeispiel dient die Traditionsmarke Caramba. Ausgangspunkt der Analyse ist das doppelte Steuerungsproblem: Zum einen gilt es, Echtzeitdaten aus Interaktionen, Reichweiten und Stimmungen zu verdichten, zum anderen sind Kampagnen in volatilen Auktionsumgebungen wirksam zu allokieren. In diesem Kontext fungiert KI als Ermöglicher einer verbesserten Wahrnehmung, Antizipation sowie teilautomatisierten Entscheidungsfindung innerhalb klar definierter Governance-Strukturen, die eine Kennzeichnung synthetischer Inhalte vorsehen.

Methodisch ist die Arbeit an einem dreistufigen Design orientiert: Zunächst erfolgt eine theoretische Fundierung auf Basis der Perspektive dynamischer Fähigkeiten. Darauf aufbauend wird ein Instagram-Audit umgesetzt, um die Formatlogik sowie bestehende Governance-Lücken zu analysieren. Abschließend wird ein kontrolliertes Experiment im Werbeanzeigenmanager durchgeführt, das sich auf Awareness-Maßnahmen konzentriert, eine zufällige Zuweisung der Probanden vorsieht und unter konstanten Rahmenbedingungen stattfindet. Dabei werden Varianten ohne Kennzeichnung mit solchen verglichen, die einen expliziten Hinweis „Mit KI generiert.“ tragen. Diese werden durch definierte Creative-Protokolle begleitet und unterliegen einer durchgehenden menschlichen Qualitätskontrolle.

Ziel der Untersuchung ist es, zu prüfen, ob KI-generierte Creatives gegenüber manuellen Varianten Effizienzvorteile erzielen können. Wissenschaftlich verbindet die Arbeit die theoretische Logik dynamischer Fähigkeiten mit einer experimentellen Feldprüfung. Praktisch liefert sie ein umsetzbares Design, das Forschungsfragen, Leistungskennzahlen, Prozessbausteine sowie Leitplanken umfasst.

Die Ergebnisse zeigen, dass KI-generierte Creatives ohne Kennzeichnung eine weitgehende Gleichwertigkeit zu manuell erstellten Varianten erreichen, während mit expliziter Kennzeichnung tendenziell Effizienzvorteile zugunsten der KI erkennbar sind. Die Aussagekraft bleibt jedoch durch den begrenzten Untersuchungszeitraum, den Kanalfokus und die ausgerichtete Zielsetzung eingeschränkt. Darauf aufbauend sollten Folgeuntersuchungen conversionnahe Ziele und längere Beobachtungszeiträume berücksichtigen, weitere Plattformen und Ausspielumgebungen einbeziehen sowie Wirkungen in Privatkundensegment und bei Geschäftskunden getrennt analysieren.

Gender-Hinweis

Zur besseren Lesbarkeit wird in dieser Masterthesis das generische Maskulinum verwendet. Die in dieser Arbeit verwendeten Personenbezeichnungen beziehen sich - sofern nicht anders kenntlich gemacht - auf alle Geschlechter.

Hilfsmittel

Zur Überarbeitung des wissenschaftlichen Schreibstils wurde **ChatGPT-5** eingesetzt.

Abbildungsverzeichnis

Abbildung 1: Participative Business Scenario development canvas by using genAI 25

Abbildung 2: Partizipative Entwicklung von Geschäftsszenarien mithilfe von genAI.....34

Abbildung 3: Partizipative Entwicklung von Geschäftsszenarien mithilfe von genAI zur Entwicklung von Creatives für das A/B-Testing 40

Tabellenverzeichnis

Tabelle 1: Instagram-Audit Caramba.....28

Tabelle 2: Ergebnisse der A/B-Tests.....45

Abkürzungsverzeichnis

AI	Artificial Intelligence
B2B	Business to Business
B2C	Business to Customer
BERT	Bidirectional Encoder Representations from Transformers
CTA	Call-to-Action
CTR	Click-Through-Rate
KI	Künstliche Intelligenz
KPI	Key Performance Indicator
LLM	Large Language Model
ML	Machine Learning
MBO	Management-Buy-out
NCP	Network Control Protocol
NLP	Natural Language Processing
OEC	Unique-Reach-pro-Euro

1 Einleitung

1.1 Problemstellung und Relevanz des Themas

Die Kommunikation in sozialen Medien ist durch eine hohe Dynamik sowohl der Umwelt als auch der jeweiligen Plattformen gekennzeichnet: Algorithmen, Formate und Wettbewerbsintensitäten verändern sich somit in kurzen Zyklen, während die Nutzeraufmerksamkeit zunehmend auf kurzformatige visuelle Inhalte fokussiert ist. Für das Social-Media-Management ergibt sich daraus ein zweifaches Steuerungsproblem. Organisationen müssen Datenströme aus Interaktionen, Reichweiten und Stimmungen in Echtzeit erfassen und verdichten. Gleichzeitig sind Inhalte und Kampagnen unter unsicheren und schwankenden Auktionsbedingungen effizient zuzuordnen (Herhausen et al., 2024, S. 1-3).

In diesem Kontext fungiert KI als Ermöglicher: Dabei automatisiert sie die Wahrnehmung (Social Listening, Sentiment-Analyse), die Antizipation (Prognosen zu Reaktionen und Timing) sowie teilweise die Entscheidungsfindung (Varianten- und Budgetsteuerung). Im Marketing wird KI daher als produktivitätssteigernde Technologie mit Kostenreduktionseffekten betrachtet, deren Nutzen jedoch maßgeblich von der Datenqualität, der Modellpassung und der Governance abhängt (Huang & Rust, 2021, S. 30-35). So können personalisierte Ausspielungen in sozialen Medien nur dann nachhaltige Verhaltenswirkungen erzielen, wenn die Relevanz klar herausgearbeitet und die Modelle kontinuierlich an den jeweiligen Kontext sowie die Datenlage angepasst werden. Andernfalls drohen Messfehler und Übersteuerung (Mariani et al., 2022, S. 497-503; Herhausen et al., 2024, S. 2-4).

Mit zunehmender Automatisierung verschärfen sich zudem die Risiken hinsichtlich Authentizität und Transparenz. Generative Systeme können den Stil bzw. die Tonalität und kulturelle Passung verfehlen. Fehler in Training und Moderation führen dann mitunter zu Verzerrungen und Fehlklassifikationen. Vor diesem Hintergrund wird in der Debatte um einen verantwortungsvollen KI-Einsatz die Notwendigkeit expliziter Qualitäts- und Kontrollmechanismen betont, um Reputations- und Fairnessrisiken im Content- und Anzeigenprozess vorzubeugen (Huang & Rust, 2021, S. 33-35). Regulatorisch ist die Richtung bereits vorgegeben: Das europäische KI-Gesetz verpflichtet zur Kennzeichnung synthetischer Inhalte gegenüber der Öffentlichkeit bzw. zu geeigneten Informationsmaßnahmen. Diese Transparenzanforderungen greifen unmittelbar in Social-Media-Workflows ein und machen eine klare Prozess-, Daten- und Rollenklärung zur Voraussetzung für skalierbare KI-Routinen (Europäische Union, 2024, Art. 50, S. 81-82).

Praktisch verdichtet sich die Problemstellung entlang dreier Spannungsfelder:

- **Effizienz:** Auktionierte Reichweiten und knappe Budgets erfordern eine nachweisbar effektivere Auslieferung pro Geldeinheit. Hierbei verspricht KI operative Hebel, deren Wirksamkeit experimentell zu prüfen ist (Herhausen et al., 2024, S. 3-4; Huang & Rust, 2021, S. 31-34).
- **Authentizität:** Marken müssen maschinell erzeugte Varianten so darstellen, dass Identität, Stil und Dialogfähigkeit gewahrt bleiben. Entsprechend gefährdet eine fehlende Passung die Beziehungsqualität und Reputation (Mariani et al., 2022, S. 504-505; Huang & Rust, 2021, S. 34-35).
- **Governance:** Ohne verlässliche Mess- und Attributionsketten, dokumentierte Freigaben sowie Kennzeichnungs- und Eskalationsregeln bleiben KI-Gewinne unsicher und nicht auditierbar; überdies erhöhen rechtliche Transparenzpflichten den Handlungsdruck (Europäische Union, 2024, Art. 50, S. 81-82).

Vor diesem Hintergrund wird in der Thesis untersucht, wie KI im Social-Media-Management die Effizienz von Content- und Anzeigenprozessen steigern kann, ohne Authentizität und Compliance zu unterlaufen. Diese Problemstellung wird in ein überprüfbares experimentelles Design am Beispiel Caramba überführt. Dabei ergibt sich die Relevanz aus der Kombination aus Marktdruck zur Effizienzsteigerung, regulatorisch geforderter Transparenz und der Notwendigkeit, dynamische Fähigkeiten datenbasiert zu operationalisieren (Huang & Rust, 2021, S. 30-35; Herhausen et al., 2024, S. 1-4; Europäische Union, 2024, Art. 50, S. 81-82).

1.2 Zielsetzung der Fragestellung

Ausgangspunkt der Thesis ist die Forschungsfrage:

Wie kann KI im Werbeanzeigenmanagement angewandt werden, um eine Effizienzsteigerung im Social-Media-Management zu erzielen, und wie müssen hierfür Content-Erstellung, Kampagnensteuerung und Werbeanzeigenmanagement angepasst werden?

Entlang der Zielsetzung wird am Beispiel von Caramba geprüft, ob KI-generierte Creatives unter identischen Bedingungen Effizienzvorteile erzielen können. So wird untersucht, ob eine transparente Kennzeichnung von Creatives mit dem Hinweis „Mit KI generiert." die Effizienz moderiert. Hieraus soll abgeleitet werden, welche Anpassungen in Content-Erstellung, Kampagnensteuerung und Anzeigenprozessen erforderlich sind, damit KI innerhalb eines messbaren governancefähigen Rahmens wirksam werden kann. Der Untersuchungsrahmen ist bewusst eng gezogen, um interne Validität zu sichern. Plattformseitig konzentriert sich der A/B-Test im Meta-Werbeanzeigenmanager auf die kampagnenzielbezogene Optimierung der

Reichweite (Awareness). Zur Absicherung der Umsetzung stützt sich die Arbeit auf das A/B-Test-Verfahren des Meta-Ökosystems.

Der wissenschaftliche Beitrag der Arbeit besteht in der Verbindung einer dynamischen-Fähigkeiten-Perspektive mit experimenteller Evidenz. Hierbei wird KI nicht nur als Kreativwerkzeug, sondern auch als Hebel einer messbaren, regelbasierten Steuerung verstanden. Wiederum liegt der praktische Beitrag in dem umsetzbaren Design aus Forschungsfrage, KPIs und Prozessleitplanken, das Organisationen befähigt, KI-basierte Werbeanzeigen effizient und transparent zu betreiben, ohne Ergebnisse vorwegzunehmen.

1.3 Methodik und Konzept der Thesis

Die Arbeit folgt einem dreistufigen Forschungsdesign aus Theorieaufbau, Social-Media-Audit und A/B-Test am Beispiel Caramba. Zunächst wird Social-Media-Management als dynamische Fähigkeit begriffen, die Sensing, Seizing und Reconfiguring erfordert. Daraus leitet sich die Notwendigkeit einer auditierbaren Mess- und Governance-Basis ab. Darauf aufbauend prüft ein Instagram-Audit die Konsistenz von Zielen, KPIs, Attribution und Prozessen, um Formatrollen, Messlücken und organisatorische Engpässe zu identifizieren. Die dritte Stufe bildet ein kontrollierter A/B-Test im Meta-Werbeanzeigenmanager, um die Effizienz KI-generierter Creatives gegenüber manuell erstellten Vergleichsassets unter identischen Rahmenbedingungen zu evaluieren. Die Ergebnisse sollen dann in Handlungsempfehlungen überführt werden.

Der A/B-Test besteht aus zwei Phasen mit demselben Awareness-Ziel und einer geografischen Ausrichtung auf Deutschland. Dabei erfolgt die Zuweisung nutzerzentriert, randomisiert und nicht überlappend. Jede Person sieht während der Laufzeit nur eine Variante; alle übrigen Einstellungen werden konstant gehalten: Placements, Bidding-Strategie, Laufzeit von sieben Tagen pro Phase. In Phase 1 wird „KI-Creative“ gegen „Human-Creative“ ohne Hinweis getestet; in Phase 2 wird der identische Vergleich um die Kennzeichnung „Mit KI generiert.“ ergänzt, um potenzielle Transparenzeffekte methodisch zu isolieren. Die Creative-Stimuli werden vorab statisch versioniert und mit Creative-Protokollen dokumentiert.

Damit verbindet die Gesamtkonzeption eine theoriegeleitete Diagnose der Ist-Prozesse mit einem experimentellen Prüfstand, der Kausalität herstellt und gleichzeitig plattformspezifische Randbedingungen wie Lernphase, Attribution und Randomisierung kontrolliert. Dieses Set-up ermöglicht eine belastbare Beantwortung der Effizienzfrage unter realen Ausspielbedingungen, ohne Ergebnisinformationen vorzugreifen.

1.4 Aufbau der Arbeit

Die Arbeit ist entlang eines Erkenntnispfads strukturiert, der von der Problemdefinition über Diagnose und Experiment zu Implikationen und Schlussfolgerungen führt; sie adressiert die Potenziale von KI im Social-Media-Management am Beispiel Caramba.

Kapitel 2 entwickelt den theoretischen Rahmen. Es systematisiert Social-Media-Management als strategisches Handlungsfeld über die funktionalen Bausteine Identität, Präsenz, Beziehungen und Reputation, verankert die Steuerung in der Logik dynamischer Fähigkeiten und ordnet KI als Ermöglicher für Social Listening, Sentiment-Analytik, Variantenbildung und Automatisierung ein. Authentizitäts-, Fairness- und Transparenzanforderungen werden als leitende Leitplanken formuliert und in Bezug zu programmatischer Ausspielung und plattformspezifischer Creative-Optimierung gesetzt.

Kapitel 3 bildet den Praxis- und Datenkontext. Es dokumentiert das Instagram-Audit mit der beobachteten Formatdifferenzierung zwischen Reels und Feed, identifiziert vier zentrale Herausforderungslinien (Soll-KPIs, Attribution, Commerce-Funktionen, Governance/Prozesse) und leitet daraus einen organisationsfähigen Mess- und Prozessrahmen für die spätere Experimentierung ab.

Kapitel 4 beschreibt das empirische Design und die Durchführung der A/B-Tests. Dargestellt werden Hypothesenfixierung, Randomisierung und Konstanthaltung der Rahmenbedingungen, die Stimulusdefinition der Creative-Arme, die KPI-Architektur mit CPM als primärem Effizienzmaß sowie OEC und Frequency als KPIs, die phasenweise Variation der Kennzeichnung „Mit KI generiert.“ und die Protokoll-, Compliance- und Pre-Flight-Checks zur Sicherung interner Validität und Replizierbarkeit.

Kapitel 5 entwickelt Zukunftsperspektiven sowie Handlungsempfehlungen. Es übersetzt theoretische wie empirische Einsichten in umsetzbare Pfade für Content-, Kampagnen- und Werbeanzeigenmanagement, konkretisiert Rollen- und KPI-Rahmen, verankert „Human-in-the-Loop“ Kennzeichnung sowie Data-/Model-Governance. Zudem priorisiert es Maßnahmen entlang der im Audit identifizierten Lücken.

Kapitel 6 diskutiert die Ergebnisse. Es ordnet die Befunde in den Theorierahmen ein, leitet praktische Implikationen ab, reflektiert Limitationen und Validitätsgrenzen des Designs und skizziert die Generalisierbarkeit auf benachbarte Kontexte.

Kapitel 7 schließt mit Fazit und Ausblick. Es fasst die zentralen Ergebnisse zusammen, konsolidiert die Handlungsempfehlungen für die operative Umsetzung und markiert Anschlussfragen für weiterführende Forschung. Insbesondere zur Wirkung von Kennzeichnung, zur kreativen Diversität unter generativen Pipelines, sowie zur Integration konversionsnaher Signale in die Steuerungslogik.

2 Theoretische Grundlagen

2.1 Grundlagen des Social-Media-Managements

2.1.1 Definition und Aufgabenfelder

Social-Media-Management hat sich zu einem strategischen Handlungsfeld entwickelt. In diesem planen, veröffentlichen, steuern und optimieren Unternehmen ihre digitalen Stakeholder-Interaktionen nicht mehr nur kanalübergreifend, sondern unternehmensweit auf Basis von Feedbackschleifen (Felix et al., 2017, S. 118-121). Damit entsprechende Strategien wirksam sind, müssen die funktionalen Bestandteile sozialer Medien verstanden werden, also Identität, Konversationen und Teilen sowie Präsenz, Beziehungen und Reputation. Sie fungieren als Gestaltungsgrößen, über die Markenkommunikation situativ ausgesteuert werden kann (Kietzmann et al., 2011, S. 243-251; Kaplan & Haenlein, 2010, S. 59-64).

Aufgrund der hohen Umwelt- und Plattformdynamik wird diese Aussteuerung als Ausdruck sogenannter „Dynamic Capabilities“ interpretiert: Hierbei müssen Unternehmen interne und externe Kompetenzen integrieren, aufbauen und neu konfigurieren, um auf Trends und Änderungen im Nutzerverhalten zu reagieren (Teece et al., 1997, S. 516; Eisenhardt & Martin, 2000, S. 1105-1108). Diese Beweglichkeit wird operativ durch Echtzeit-Monitoring und Performance-Analysen abgesichert, die den laufenden Erfolg der Maßnahmen überprüfen (Peters et al., 2013, S. 282-285).

Darüber hinaus ist KI im Social-Media-Management zu einem zentralen Ermöglicher datengetriebener Routinen geworden. Sie unterstützt Social Listening, Sentiment- und Kommentaranalysen sowie automatisierte Interaktionen wie Chatbots und automatische Antworten. Ferner ermöglicht sie kennzahlenbasierte Reports und die adaptive Steuerung von Contentportfolios (Davenport et al., 2020, S. 24-29; Liu, 2012, S. 7-12; Peters et al., 2013, S. 282-285; Huang & Rust, 2018, S. 156-162). Gleichzeitig verschärfen Automatisierung und algorithmische Intermediation entsprechende Authentizitätsrisiken. Wenn Kommunikationssignale verwischt und Bots als nichtmenschliche Akteure auftreten, können die Wahrnehmung und Beziehungsqualität beeinträchtigt werden - insbesondere wenn Transparenz, Passung und menschliche Anschlusskommunikation fehlen (Ferrara et al., 2016, S. 96-100; Audrezet et al., 2020, S. 557-563).

Für Traditionsmarken stellt die Balance zwischen Automatisierung, Authentizität und Glaubwürdigkeit eine besondere Herausforderung dar. Ihre Unverwechselbarkeit beruht auf Identitätsankern, die wiederum auf digitalen Touchpoints konsistent, transparent und dialogisch

übersetzt werden müssen, um trotz Automatisierung nahbar zu bleiben (Urde et al., 2007, S. 4-12; Peters et al., 2013, S. 286-292). Hierbei professionalisiert KI-gestützte Content-Erstellung die redaktionelle Wertschöpfung im Social-Media-Management. So antizipieren generative und prädiktive Verfahren für das Engagement relevante Merkmalsbündel von Beiträgen. Der Veröffentlichungszeitpunkt beeinflusst die Nutzerreaktion deutlich. Beiträge, die morgens ausgespielt werden, erzielen demnach höhere Klickwahrscheinlichkeiten (Kanuri et al., 2018, S. 2-4). Auch Posting-Tag und Uhrzeit sowie die mediale Ausgestaltung wirken als Treiber für Likes, Kommentare und Shares (kumuliert als Interaktionen oder Engagement) (Pletikosa Cvijikj & Michahelles, 2013, S. 844-846; de Vries et al., 2012, S. 86-90). Authentizität bleibt dabei eine strategische Leitplanke: KI übernimmt zwar analytische Aufgaben und Teile intuitiver Tätigkeiten, erreicht jedoch vorerst nicht die empathische Qualität zwischenmenschlicher Interaktion. Deshalb kann eine unreflektierte Automatisierung die Beziehungsqualität bzw. Vertrauenswahrnehmung beeinträchtigen (Huang & Rust, 2018, S. 156-160; Hermann, 2022, S. 44-47).

Social Listening und Community-Management fungieren als präzise Schnittstelle zwischen Unternehmen und Zielgruppen. In diesem Zusammenhang erfassen KI-gestützte Systeme öffentliche Diskurse in Echtzeit, identifizieren aufkommende Krisen und ermöglichen eine rechtzeitige Kommunikation, um Reputationsschäden zu begrenzen. Für die operative Priorisierung - etwa bei der Verteilung von Moderationskapazitäten oder Kampagnenbudgets - ist eine entsprechend hohe Prognosegüte zentral (Westermann et al., 2021, S. 239-249). Da KI-optimiertes Social Listening das Erfassen, Strukturieren und Bewerten öffentlich verfügbarer Beiträge automatisiert, bleiben auch bei wachsender Datenmenge eine konsistente, individuelle Ansprache und eine frühzeitige Eskalationserkennung möglich, während der manuelle Aufwand sinkt (Westermann et al., 2021, S. 239-249).

2.1.2 Content-Erstellung und Kampagnenmanagement

Content-Erstellung und Kampagnenmanagement werden von KI geprägt, indem analytische und prädiktive Modelle heterogene Nutzerdaten aus Historie, Verhalten und Präferenzen integrieren. Von dieser Grundlage aus lassen sich thematisch relevante und aktuelle Beiträge ableiten, die Interaktionen fördern und die Zielgruppenansprache präzisieren (Kumar et al., 2024, S. 7-12). Hierbei senken automatisierte Pipelines den manuellen Aufwand und steigern die Prozesseffizienz. Jedoch hängt ihre Wirksamkeit von der Qualität, Aufbereitung und Repräsentativität der zugrunde liegenden Social-Media-Daten ab (Hoffmann & Zerres, 2017, S. 10-12). Big-Data-Verfahren wie Feature-Engineering (Umwandlung und Anrei-

cherung von Daten) und prädiktive Modellierung (Bewertung von Daten und Analyse von Mustern) erfordern eine entsprechend robuste Datenvorbereitung, da Modellleistung und inhaltliche Relevanz stark von der Qualität und Granularität der Daten abhängen (Gandomi & Haider, 2015, S. 139-142). Zudem eröffnet die Integration demografischer, Interaktions- und Verhaltensdaten in die personalisierte Content-Erstellung neue Perspektiven für die Markenkommunikation. Marketing-Analytics-Ansätze zur Personalisierung - etwa auf Basis von Verhalten und Kaufhistorie - operationalisieren diese Zusammenführung und ermöglichen eine präzise Zielgruppenansprache. Bei gesicherter Datenqualität, Vielfalt und Pflege führt dies zu Effizienzgewinnen im Social-Media-Marketing (Bleier & Eisenbeiss, 2015, S. 669-688; Stieglitz et al., 2018, S. 157-165). Predictive-Analytics-Modelle wie Google Trends und Social Listening erkennen Strömungen, erfassen Saisonalität und Präferenzverschiebungen und schätzen die erwartete Resonanz geplanter Beiträge, wodurch die Contentstrategie vorausschauend angepasst werden kann (Moro et al., 2014, S. 24-26). Diesbezüglich hängt die Wirksamkeit datengestützter Markenkommunikation wesentlich von der Qualität und Vielfalt der verwendeten Datensätze ab. Somit führt mangelnde Datenheterogenität zu verzerrten Ergebnissen und erschwert eine zielgenaue Ansprache spezifischer Zielgruppen (Cubric, 2020, S. 5-11).

Daher wird die kontinuierliche Erweiterung und Aktualisierung des Datenpools zum zentralen Wettbewerbsfaktor. In diesem Zusammenhang können KI-Systeme aus Echtzeitdaten und Sentimentanalysen automatisiert Erkenntnisse extrahieren, die die inhaltliche Gestaltung steuern (Provost & Fawcett, 2013, S. 317-322; Fan & Gordon, 2014, S. 74-81; Gooljar et al., 2024, S. 1-2, 23-24). Sentimentanalysen erfassen Onlinekommentare in Echtzeit und liefern standardisierte Messgrößen emotionaler Reaktionen. Hier besteht die Herausforderung darin, diese Erkenntnisse zeitnah umzusetzen, ohne durch eilige Eingriffe das Markenvertrauen zu gefährden (Rodríguez-Ibáñez et al., 2023, S. 2-6). Laut Huang und Rust (2021, S. 31-35, 46-48) erhöhen solche Technologien die Produktivität und reduzieren Kosten. Zudem ermöglicht die automatische Erfassung visueller Präferenzen, Stimmungen und demografischer Daten eine zielgerichtete Anpassung von Kampagnen an ein dynamisches Wettbewerbsumfeld. Dabei ist sicherzustellen, dass die verwendeten Algorithmen frei von impliziten Verzerrungen sind und keine Mehrheitspräferenzen verstärken.

Generative KI-Modelle produzieren auf Grundlage probabilistischer Verfahren automatisch Texte, Bilder und Videos. So können sie in kurzer Zeit umfassende Mengen an Varianten generieren und sind damit vorteilhaft bei hohem Wettbewerbsdruck und der Nachfrage nach differenzierten Inhalten (Grewal et al., 2025, S. 702-705). Diese maschinelle Effizienz entlastet Kreativabteilungen und sorgt für eine konsistente Markenpräsenz. Hierbei ist zu beachten,

dass KI-generierte Inhalte ohne menschliche Mitwirkung an Tiefe und kultureller Passung verlieren können bzw. die Tonalität und der Kontext häufig verfehlt werden. Deshalb bleibt eine menschliche Qualitätskontrolle notwendig. Generative Modelle eignen sich entsprechend als Inspirationsquelle, während menschliche Kreativität die Verfeinerung und strategische Anpassung übernimmt (Israfilzade, 2024, S. 557-562).

Im Kampagnenmanagement tragen KI-gestützte Analysemethoden zu präziserer Segmentierung und flexibler Budgetverteilung bei. In A/B-Tests - hier handelt es sich um kontrollierte Experimente mit parallel ausgespielten Varianten - können Algorithmen unterschiedliche Anzeigen oder Botschaften generieren und gleichzeitig testen. Echtzeit-Analytics identifizieren suboptimale Varianten und ermöglichen unmittelbare Optimierungen (Ur Rahaman, 2023, S. 4-8). Laufende Dashboards zeigen wiederum Kennzahlen wie Klick- und Konversionsraten. Somit können Budgets auf besser performende Segmente verschoben werden, und es ist möglich, die Ansprache entsprechend anzupassen.

Dies erhöht das Engagement (bzw. die Interaktionen) und senkt die Werbekosten. Im Rahmen der Literatur wird jedoch diskutiert, ob Automatisierung kreative Expertise vollständig ersetzen kann oder ob die Kooperation von menschlichem Urteilsvermögen und algorithmischer Effizienz langfristig überlegen bleibt (Pauwels et al., 2009, S. 175-176, 186-188; Gigli & Stella, 2025, S. 151-153, 160-163; Huang & Rust, 2021, S. 46-48). Maschinelles Lernen (ML) ermöglicht diesbezüglich eine fortlaufende Analyse von Zielgruppenverhalten und Kampagnenreaktionen. Fan und Gordon (2014, S. 74-79) sowie Reuter und Kaufhold (2021, S. 407-410, 421-424) betonen, dass entsprechende Algorithmen Unternehmen helfen, die Dynamik wachsender Contentmengen bzw. budgetärer Veränderungen unter steigenden Erwartungshaltungen zu bewältigen. Für mittelständische Unternehmen ist dies bedeutsam, weil Trends und Krisen im Social-Media-Umfeld frühzeitig erkannt und darauf abgestimmte Interventionen entsprechend geplant werden können. Diese Anpassungsfähigkeit erhöht die Wahrscheinlichkeit, dass Kampagnen erfolgreich sind und die Kundenbindung stärken. Sia et al. (2022, S. 251-274) hinterfragen hingegen, ob datengetriebene Strategien bei kleinen und mittleren Unternehmen ausreichend individualisiert sind. Während datenwissenschaftliche Methoden die Effizienz digitaler Marketingstrategien steigern, nehmen zugleich die organisatorische und technische Komplexität der Umsetzung zu.

2.1.3 Meta-Werbeanzeigenmanagement

Der Meta-Werbeanzeigenmanager fungiert als zentrales, datenbasiertes System zur Planung, Ausspielung und Erfolgsmessung von Kampagnen über Facebook, Instagram, Messenger und

das Audience Network. Über „Click-to-WhatsApp“-Formate lässt sich auch WhatsApp nahtlos einbinden, wodurch Reichweite und Kanalintegration für heterogene Zielgruppen skalierbar werden (Meta Business Help (G), o. D.; WhatsApp Business, o. D.). So automatisieren KI-gestützte Funktionen wie „Advantage Plus“ die Zielgruppenfindung, Budgetverteilung und kreative Variation in Echtzeit - ein Ansatz, der im Kontext von Programmatic Advertising (PA) verortet werden kann. Laut Meta steigern die generativen „Advantage Creative“-Funktionen im Durchschnitt die Klickrate um 11 % und die Conversion-Rate um 7,6 %, ohne dass das eingesetzte Budget erhöht wird (Meta, 2024). Dabei beschleunigt PA dieses Wachstum zusätzlich, da einzelne Impressionen automatisiert und in Echtzeit gehandelt werden (IAB Tech Lab, 2016, S. 6-8). Anhand des US-Markts lässt sich die Relevanz verdeutlichen. So beliefen sich die PA-Umsätze 2022 auf 109,4 Mrd. US-Dollar - ein Zuwachs von 10,5 % gegenüber 2021 (IAB & PwC, 2023, S. 16-18). Diese Automatisierung reduziert manuelle Prozessschritte, minimiert Streuverluste und erhöht die Präzision der Budgetallokation. Gleichwohl bleibt die qualitative Bewertung von Kreativinhalten, Markenpassung und strategischer Positionierung eine Domäne menschlicher Expertise, die durch KI zwar ergänzt, aber nicht ersetzt wird (Huang & Rust 2021, S. 31-33).

Die im Meta-Werbeanzeigenmanager konsolidierten Profil- und Verhaltensdaten ermöglichen eine präzise personalisierte Zielgruppenansprache (Federal Trade Commission, 2014, S. 26, 46). Darauf basierend entscheiden lernbasierte Algorithmen automatisiert über Platzierung und Ausspielung, während Inhalte adaptiv an individuelle Interessenprofile angepasst werden. Darüber hinaus können eine transparente Datenerhebung und eine angemessene Personalisierungstiefe Klick- und Reaktionsraten erhöhen, während verdeckte Datennutzung oder eine übermäßige Spezifität kontraproduktive Effekte hat (Aguirre et al., 2015, S. 35, 39-40, 44).

Besondere Potenziale zeigen sich bei KI-gestützten Kurzvideoanzeigen, deren Wirksamkeit von der systematischen Abstimmung von Gestaltung, Format und Inhalt auf Nutzerkontexte abhängt. Vertikale Videos im 9:16-Format erhöhen nachweislich das Engagement gegenüber horizontalen Formaten, da sie leichter rezipiert werden (Mulier et al., 2021, S. 1-3, 7-10). Generativ erzeugte Werbebilder übertreffen teilweise schon menschliche Motive in Qualität, Realismus und Ästhetik. Dabei erzielen KI-generierte Banner eine um bis zu 50 % höhere Klickrate (CTR) bei deutlich geringeren Produktionskosten (Hartmann et al., 2025, S. 22). Dies stützt die Annahme, dass generierte visuelle Werbemittel unter bestimmten Bedingungen Leistungswerte human erstellter Assets erreichen oder übertreffen können, wenngleich A/B-Tests unerlässlich bleiben. Ergänzend zeigt Drydakis (2022, S. 1223-1247), dass KI-gestütztes Werbeanzeigenmanagement Prozesse automatisiert, Ressourcen schont und Marktergebnisse

beschleunigt. Für kleine und mittlere Unternehmen sind damit messbar geringere Geschäftsrisiken verbunden, wodurch Leistungsverbesserungen begünstigt werden. Zusammengenommen untermauern diese Ergebnisse, dass Automatisierung manuelle Dispositionen ersetzt. Hierbei werden Human- und Finanzressourcen effizienter gebunden und Test- und Implementierungszyklen durch kontinuierliches Lernen verkürzt.

2.1.4 Herausforderungen im Social-Media-Management

Die zentralen Herausforderungen des Social-Media-Managements liegen in fehlender Datenintegration, isolierten Datensilos und uneinheitlicher Datenqualität. Diese Faktoren begrenzen den Einsatz lernender Systeme für Inhalte, Kampagnen und Anzeigen. Überdies verfügen mittelständische Unternehmen häufig nicht über verbundene Marketing-, CRM- und Analyseumgebungen, wodurch Datenzugriffe fragmentiert sind. Prognosemodelle beruhen dann auf kleinen Stichproben, und operative Entscheidungen verzögern sich entsprechend. Deshalb sind einheitliche Datenmodelle und Schnittstellen sowie klare Regeln der Data-Governance fundamentale Voraussetzungen (Stieglitz et al., 2018, S. 156-159; Torre-Bastida et al., 2022, S. 69-73).

Mohammed et al. (2025, S. 14-15) testeten 19 gängige Machine-Learning-Algorithmen unter Variation von sechs Datenqualitätsdimensionen wie Vollständigkeit, Genauigkeit, Klassenbalance und Konsistenz. Bereits geringe Qualitätsverluste führten hier zu einer Reduzierung der Modellleistung um 5 bis 15 %. Daraus folgt, dass integrierte Datenpipelines, qualitätsgesicherte Trainings- und Servicedaten sowie transparente Verantwortlichkeiten keine Begleitaufgaben, sondern zentrale Voraussetzungen darstellen in Hinblick auf skalierte, wirksame und streuverlustarme KI-gestützte Social-Media-Kampagnen.

Eine weitere Herausforderung bildet die Akzeptanz der Mitarbeitenden. So weckt die Einführung von KI in Arbeitsprozessen häufig das Gefühl von Kontrollverlust, Misstrauen und Angst vor Arbeitsplatzverlust. Ohne geeignete Schulungsangebote fühlen sich Angestellte dem Wandel gegenüber überfordert und arbeiten ungern mit KI-Systemen (EY, 2024). Gerade in mittelständischen Unternehmen mit begrenztem Personalbudget sind Investitionen in Schulungen und Weiterbildungen unumgänglich, denn der sichere Umgang mit KI setzt Schulungen und Erfahrung voraus. Beschäftigte mit höherer KI-Kompetenz nutzen KI-Tools besser und blicken optimistischer in die KI-gestützte Zukunft. Eine aktive Befähigung der Mitarbeitenden und transparente Kommunikation sowie die Einbindung der Belegschaft in die Entwicklung von Algorithmen und Entscheidungsprozessen stärken das Vertrauen und steigern die Akzeptanz (IFH KÖLN/ECC KÖLN, 2025, S. 1-2).

Mit steigendem Automatisierungsgrad verschieben sich überdies die Kompetenzanforderungen im Social-Media-Management: Routinetätigkeiten entfallen demnach, während kreative und strategische Fähigkeiten, Datenanalyse, algorithmische Steuerung sowie Kenntnisse zu Fairness und Transparenz von KI zunehmend gefragt sind. Diesbezüglich wurde im „Journal of the Academy of Marketing Science“ auf Basis von Daten zu 33 007 chinesischen Hightech-Unternehmen eine umfassend angelegte, mehrjährige Panelstudie durchgeführt. Hier zeigte sich, dass der Einsatz von KI im Marketing die Profitabilität, Neukundengewinnung und Kundenzufriedenheit signifikant verbessert. Gleichzeitig wirken Widerstände in der Belegschaft hemmend, was die Relevanz systematischer, auf Kompetenzmodelle abgestimmter Weiterbildung unterstreicht (Mu & Zhang, 2025, S. 1104-1111).

Schließlich stellt die fehlende Integration von KI in die Unternehmensstrategie eine weitere Hürde dar. Oftmals fehlen definierte Strategien und Leitfäden für den KI-Einsatz. Projekte werden dann isoliert vorangetrieben, sodass KI-Systeme nicht mit anderen strategischen Initiativen harmonisieren. Ohne klare Steuerung können schließlich negative Auswirkungen auf die Marke entstehen (IFH KÖLN/ECC KÖLN, 2025, S. 1-2; Davenport & Ronanki, 2018, S. 110-112).

2.2 Grundlagen der Künstlichen Intelligenz

2.2.1 Grundlagen und historische Entwicklung

Im Marketing bezeichnet KI ein Bündel datengetriebener Verfahren zur Automatisierung kognitiver Prozesse wie Lernen, Prognose und Entscheidungsfindung. Zu den zentralen Bausteinen gehören ML, Natural-Language-Processing (NLP) und analytische Modellierung. Im Social-Media- und Werbeanzeigenmanagement vollzieht sich diesbezüglich ein Übergang von klassischen Verfahren hin zu transformerbasierten Modellen. Diese verbessern die Textklassifikation und die Zielgruppenansprache sowie automatisierte Anzeigentexte in bedeutendem Maßstab, verlangen zugleich aber eine sorgfältige Einbettung in Governance und Ethik (Hartmann & Netzer, 2023, S. 191-195, 206). Jene Technologien verarbeiten umfassende Datenmengen, prognostizieren das Nutzerverhalten und ermöglichen personalisierte Markenerlebnisse (Verma et al., 2021, S. 2-3). Wegen ihrer Komplexität und Intransparenz sind allerdings klare Überprüfungsmechanismen notwendig, um algorithmische Verzerrungen zu vermeiden (AI HLEG, 2019, S. 3-4).

Die Entwicklung von KI verlief nicht linear, sondern in Zyklen von Fortschritt und Ernüchterung. Erste Forschungsarbeiten datieren aus den 1950er Jahren; spezifische Marketinganwendungen setzten aber erst in den 1980er Jahren mit wissensbasierten Expertensystemen ein

(Vlačić et al., 2021, S. 188). Ein weiterer Schub ging von der Verfügbarkeit erheblicher Datenmengen, wachsender Rechenleistung und neuen Verfahren des ML aus (Vlačić et al., 2021, S. 188; Ma & Sun, 2020, S. 482). Seit den 2010er Jahren ermöglichen es Deep-Learning-Ansätze, unstrukturierte Text- und Bilddaten zu verarbeiten, und eröffnen präzisere Personalisierung und entsprechendes Targeting (Ma & Sun, 2020, S. 482-484). Wiederum der Durchbruch funktionsübergreifender KI im Marketing ist auf die späten 2010er Jahre datiert, als Fortschritte in Machine und Deep Learning komplexere autonome Anwendungen praxistauglich machten (Kumar et al., 2024, S. 4).

Cristofaro und Giardino (2025, S. 2-5) beschreiben fünf Wellen der Entwicklung der KI. In der ersten Welle („Zero hour") dominierten einfache, regelbasierte Systeme, die nur vorgegebene Dialoge abbildeten und durch die begrenzte Rechenleistung stark eingeschränkt waren. Im Rahmen der zweiten Welle wurden revolutionäre NLP- und statistische Methoden eingeführt. Erste Systeme nutzten Mustererkennung und skriptbasierte Emotionen, um menschliche Gespräche besser nachzuahmen. In der dritten Welle („kick-off") rückten durch technologische Fortschritte ab Mitte der 2000er Jahre multimodale Systeme und Produkte wie IBM Watson in den Vordergrund, wobei Begriffe wie „AI", „Chatbot" und „Human-Computer Interaction" diese Phase prägten. Die vierte Welle („Hype-Welle") wurde durch den Smartphone-Boom und Fortschritte in KI und NLP getragen. Aus textbasierten Anwendungen wurden hier sprachgesteuerte Assistenten wie Siri und Alexa, die sich im Alltag etablierten und breite Investitionen auslösten. Die fünfte Welle („AI-Welle") zeichnet sich schließlich durch großskalige Sprachmodelle und zunehmende Autonomie aus und verspricht selbstlernende, realzeitadaptive Agenten, erfordert aber neue Governance-Konzepte zur Steuerung der Risiken. Fortschritte entstehen demnach, wenn skalierbare Modelle auf ausreichende Hardware und reichhaltige Datensätze treffen. Stagnierende Phasen („AI-Winter") treten hingegen ein, wenn eines dieser Elemente fehlt.

2.2.2 Technologien und Anwendungen im Überblick

Bezogen auf das Marketing kann KI-basierte Personalisierung in zwei Bereiche unterteilt werden: in prädiktive Modelle, die Zielgruppen, Timing und Relevanz optimieren; sowie in generative Systeme, die Texte, Bilder und Dialoge automatisch erstellen. Generative Verfahren sind bereits wirksam in Social-Media-Content integriert, während analytische KI vor allem für Segmentierung und Targeting genutzt wird. Unabhängig vom Ansatz bleibt die Verfügbarkeit hochwertiger Daten entscheidend; somit stellen fehlerhafte oder halluzinierte KI-Ausgaben weiterhin ein relevantes Risiko dar (Grewal et al., 2025, S. 702-705).

Intelligente Datenmanagementstrukturen und ein explizites Data-Analytics-Governance-Framework lösen Datensilos auf und sichern Datenqualität sowie Zugriffsrechte. Dadurch schaffen sie die Voraussetzung für KI-gestütztes Marketing über integrierte Quellen wie CRM und externe Marktdaten (Baijens et al., 2022, S. 103-104). Dabei automatisiert KI zentrale Marktforschungs- und Analyseprozesse, indem sie umfassende Mengen unstrukturierter Text-, Bild- und Tracking-Daten für Prognosen, Segmentierung und Personalisierung nutzbar macht. Gleichzeitig erfordert ihr Einsatz interpretierbare Verfahren und analytische Kompetenz im Team (Ma & Sun, 2020, S. 482-484, 493-496). Insbesondere kleine und mittlere Unternehmen zögern diesbezüglich noch aufgrund von Infrastrukturdefiziten, begrenzten Budgets, fehlendem Fachpersonal sowie rechtlichen und organisatorischen Hürden. Jedoch werden Kooperationen mit Start-ups, Hochschulen und Förderökosystemen als praktikable Hebel zur Mobilisierung von Kompetenzen und Ressourcen beschrieben (Schwaeke et al., 2024, S. 1315-1317).

Integrierte Datenmanagement- und Data-Governance-Strukturen konsolidieren fragmentierte Quellen und machen sie für KI-gestützte Marketinganwendungen nutzbar. In der Fachliteratur werden dafür Modelle beschrieben wie Datenpools, -genossenschaften und -treuhänder, die geteilte und qualitätsgesicherte Datenströme für Analysen eröffnen (Micheli et al., 2020, S. 6-9). Allerdings erfordert die Umsetzung sowohl Investitionen in skalierbare IT-Infrastrukturen als auch die automatisierte Integration von CRM-Daten und externen Marktdaten sowie ein formalisiertes Data-Governance-Konzept, das Rollen, Qualitätsregeln und Zugriffsrechte definiert. Zugleich verlangt die Interpretation KI-basierter Ergebnisse ausgewiesene Daten- und Methodenkompetenz im Team (Davenport et al., 2020, S. 38). Darüber hinaus übernimmt KI zunehmend informationsintensive Aufgaben der Marktforschung, Segmentierung und Kampagnenoptimierung. Human-in-Loop-Ansätze gewährleisten hier die Qualitätssicherung und halten die menschliche Kontrolle aufrecht (Davenport et al., 2020, S. 38). Hieraus ergeben sich auch typische Herausforderungen - etwa begrenzte Budgets, fehlende digitale Kompetenzen und veraltete Systeme. Als Gegenmaßnahmen können Qualifizierung und Kooperationen mit Technologieanbietern oder Hochschulen benannt werden (Kallmuenzer et al., 2025, S. 2012-2014).

3 Aktueller Stand in Wissenschaft und Praxis

3.1 Status quo der Wissenschaft: Anwendungsfelder von KI

3.1.1 Content-Erstellung und -Optimierung durch KI

Generative Sprach-, Bild- und Videomodelle automatisieren grundlegende Phasen der Content-Erstellung. Dabei erlauben sie datenbasierte Variantenbildung und eine laufende Optimierung von Inhalten. Jedoch hängt die Leistungsfähigkeit solcher Modelle wesentlich von der Qualität, Repräsentativität und Dokumentation der Trainingsdaten ab. Wenn diese aus ungefilterten Webkorpora stammen, können führende Sichtweisen und diskriminierende Muster verstärkt werden. Um dies zu vermeiden, sind kuratierte Datenerhebung, systematische Datenqualitätsprüfungen und dokumentierte Audits erforderlich (Bender et al., 2021, S. 610-617).

Für die Contentoptimierung mit generativer KI sind Datenqualität und Aktualität unabdingbar; andernfalls häufen sich Fehlklassifikationen und verzerrte Empfehlungen. Funktionale Stresstests zeigen ausgeprägte Schwächen gängiger Transformer-Modelle. Gemäß der Hate-Check-Studie von Röttger et al. (2021, S. 41-58) versagen BERT-Modelle (zur Entschlüsselung komplexer Sprachmuster) (Bidirectional Encoder Representations from Transformers) und kommerzielle Moderationsdienste häufig bei der Erkennung negierter Hassäußerungen und nicht hasserfüllter „reclaimed slurs“ und weisen gruppenspezifische Genauigkeitslücken auf, etwa bei Beiträgen über Frauen. Für die operative Praxis folgt daraus ein doppelter Qualitätsmechanismus. Zum einen sind regelmäßige Blackbox-Tests erforderlich, die bestimmte Funktionsklassen (z. B. Negation, ironische Kontexte) abdecken, zum anderen müssen Modelle zeitlich adaptiert werden, um sprachliche Veränderungen auf Social-Media-Plattformen berücksichtigen zu können. Agarwal et al. (2022, S. 905, 916) identifizieren diesbezüglich zwei Methoden zur zeitlichen Anpassung ohne manuelle Annotation: das kontinuierliche Vortraining und das selbstetikettierte Feintuning; so zeigen die Autoren, dass selbstbeschriftete Aktualisierungen die zeitliche Anpassung konsistent verbessern und in einzelnen Fällen sogar eine erneute Feinabstimmung mit manuell neu gelabelten Daten übertreffen.

Ein weiteres Potenzial liegt in der visuellen Optimierung von Social-Media-Content. Kanuri et al. (2024, S. 174-181) maßen in ihrer Studie mithilfe von Computer-Vision-Algorithmen und Eye-Tracking, wie farbliche Komplexität die Aufmerksamkeit beeinflusst. Die Forschenden definieren Farbkomplexität hier als Variation der Farben über die Pixel eines Bildes und zeigen, dass Beiträge mit komplexeren Bildern mehr Aufmerksamkeit erhalten und zu höherem Engagement führen. Dabei wird der Effekt gar verstärkt, wenn Posts später am Tag veröffentlicht werden und die Bilder größer dargestellt sind, bzw. abgeschwächt, wenn der begleitende Text

negatives Sentiment enthält. Diese Erkenntnisse ermöglichen es, visuelle Assets systematisch entlang messbarer Merkmale wie Farbverteilung, Bildhöhe und Text-Bild-Abstimmung zu variieren. Außerdem können die Ergebnisse mithilfe kontrollierter Tests in die Contentstrategie zurückgespielt werden, um Kampagnenleistung und Präferenzen insbesondere bei jüngeren Zielgruppen zu erhöhen (Kanuri et al., 2024, S. 174-181).

3.1.2 KI-basierte Kampagnenplanung und Steuerung

Im Rahmen von KI-basierter Kampagnenplanung wird ML zur Mustererkennung in Verhaltens- und Interaktionsdaten mit präziser Segmentierung und Aussteuerung kombiniert. Dabei führen personalisierte Ausspielungen in sozialen Medien tendenziell zu stärkeren Verhaltenswirkungen, wenn die Relevanz für die adressierten Zielgruppen klar herausgestellt wird (Mariani et al., 2022, S. 756-758). Predictive-Analytics-Verfahren nutzen hier historische Interaktionen, um Reaktionen, saisonale Schwankungen und optimale Postingzeiten vorherzusagen. Zudem unterstützen sie die Budgetallokation sowie die laufende Optimierung von Kreativkonzepten und Zielgruppen (Herhausen et al., 2024, S. 1-4). Voraussetzung für verlässliche Prognosen ist eine aktuelle, vielfältige und qualitativ hochwertige Datenbasis. Unzureichende Informationsqualität oder fragmentierte Datensilos verzerren hingegen Segmente, verschlechtern die Modelle und schwächen die Wirksamkeit von Kampagnen (Sheth & Kellstadt, 2021, S. 782; Herhausen et al., 2024, S. 3-4). Regelmäßige Datenpflege und eine enge Zusammenarbeit zwischen Marketing und IT erhöhen wiederum die Prognosegüte und Robustheit der Modelle, womit die Leistungsfähigkeit KI-gestützter Kampagnenplanung gesichert wird (Herhausen et al., 2024, S. 4-5).

Reinforcement-Learning- und Bandit-Verfahren unterstützen überdies die Kampagnensteuerung, indem sie die Auswahl von Anzeigenvarianten datenbasiert beschleunigen und auf eine Maximierung der Click-Through-Rate (CTR) ausrichten. Hybrid-Bandits mit visuellen Priors ermöglichen es, neue Creatives trotz Cold Start schnell und kontextspezifisch zu ranken. Ein großskaliger Test mit rund 1,7 Millionen Creatives und 500 000 Produkten belegt die Wirksamkeit dieser Methode gegenüber starken Baselines (Wang et al., 2021, S. 2324-2327, 2330-2333). Auf Portfolioebene verbessern kontextuelle Bandits die Verteilung von Geboten und Budgets. In Replays realer Display-Daten zeigt ein parametrischer Bayesian-Bandit niedrigere Verluste als gängige Alternativen. Je nach Setting entsprach die Nichtnutzung des Verfahrens bis zu 40 % weniger Conversions - insbesondere bei engen Budgets oder zahlreichen Anzeigengruppen (Gigli & Stella, 2025, S. 160-163).

Zugleich erfordern KI-generierte Anzeigen besondere Sorgfalt. Untersuchungen zu Text-zu-Bild-Modellen dokumentieren eine Überrepräsentation weißer, männlicher Darstellungen bei generischen Personenprompts und eine Zunahme stereotyper Bildinhalte nach Exposition mit nicht inklusiven Beispielen. Deshalb sind Qualitäts- und Fairness-Reviews mit klar definierten Ausschlusskriterien sowie eine menschliche Freigabeinstanz vor der Ausspielung obligatorisch (AlDahoul et al., 2025, S. 2-3, 10-11).

Echtzeitanalysen sozialer Medien ermöglichen es zudem, sowohl Stimmungsumschwünge, Trends und potenzielle Krisen frühzeitig zu erkennen als auch Kampagnen in Motiv, Timing und Budget dynamisch anzupassen. Proaktive Reaktionen können die wahrgenommene Krisenwahrscheinlichkeit entsprechend senken und Verhaltensintentionen positiv beeinflussen, wenn Signale zeitnah aufgegriffen werden (Lee, 2013, S. 4-6). Eine solche Reaktionsfähigkeit setzt eine belastbare, automatisierte Datenpipeline voraus, die erhebliche aktuelle Datenmengen kontinuierlich erfasst, aufbereitet und bereitstellt. Somit zeichnet sich der KI-Einsatz im Marketing aus durch die laufende Optimierung von Zielgruppen, Creatives und Ausspielungszeitpunkten. Hierdurch entstehen hohe Anforderungen an Datenqualität und -integration (Kumar et al., 2024, S. 7-10). Zugleich gelten fragmentierte Systeme, fehlende Standardschnittstellen und Qualifikationsdefizite insbesondere in mittelständischen Unternehmen als zentrale Hemmnisse. Eine systematische Übersichtsarbeit zu Data-Driven Marketing und eine aktuelle Handelsstudie identifizierten Datenmanagement und Personalthemen als bedeutendste Hürden für KI-Implementierungen (Rosário & Dias, 2023, S. 5-12; IFH/ECC KÖLN, 2025, S. 2-3). Um die Effizienz der Kampagnenplanung zu steigern, sind daher Investitionen in integrierte Datenarchitekturen, standardisierte Schnittstellen sowie Schulungsprogramme erforderlich.

3.1.3 Social Listening und Sentiment-Analyse durch KI

Unternehmen sind mithilfe von KI-gestütztem Social Listening in der Lage, Social-Media-Daten nahezu in Echtzeit systematisch zu erfassen, aufzubereiten und zu interpretieren; dadurch werden Trendbrüche, Verschiebungen der Markenwahrnehmung und aufkommende Kommunikationskrisen frühzeitig sichtbar. So misst ein plattformübergreifend replizierbarer Social-Media-Brand-Reputation-Tracker zuverlässig die Markentreiber (Beitragsvolumen und Sentiment) im Wochen- bis Quartalsrhythmus und korreliert diese Echtzeit-Daten mit finanziellen Ergebnissen, sodass Marken bei negativen Ausschlägen sofort gegensteuern können (Rust et al., 2021, S. 21-27, 26-27). Darüber hinaus unterstützen automatisierte Sentiment-Analysen die objektive Wirkungskontrolle von Kampagneninhalten. Diesbezüglich wurde eine Meta-Analyse im „International Journal of Research in Marketing“ von Forschenden der Technischen

Universität München und der Universität Hamburg durchgeführt. Dies basierte auf 272 Datensätzen mit 12 Mio. gelabelten Texten. Hierbei zeigte die Analyse, dass Transfer-Learning-Modelle gegenüber gängigen Lexika eine im Mittel um über 20 Prozentpunkte höhere Klassifikationsgenauigkeit erzielen. Zugleich hängt die Güte vom Anwendungsfall und von der Textlänge ab, sodass eine regelmäßige Modellkalibrierung erforderlich bleibt. Dies reduziert Fehlklassifikationen und erhöht die Aussagekraft von Monitorings für inhaltliche Anpassungen (Hartmann et al., 2025, S. 75-87).

In Hinblick auf die Verlässlichkeit solcher Auswertungen ist die Datenqualität ausschlaggebend. Ein Beitrag in „Business & Information Systems Engineering“ der Universität Jaume führt ein multidimensionales Qualitätsmodell mit den Dimensionen „Glaubwürdigkeit“, „Nützlichkeit“, „Vollständigkeit“ und „Reputation“ ein. Zudem wird gezeigt, wie qualitätsgeleitetes Filtern irrelevante oder irreführende Posts reduziert und so die Aussagekraft von Social-Media-Analysen erhöht (Aramburu et al., 2024, S. 667-689). In der Praxis sollten Volumenmetriken wie Nennungen, Erwähnungen und Hashtags deshalb stets gemeinsam mit fein granularen Sentiment-Signalen und Tonalitätswechseln überwacht werden. Überdies sollten die zugrunde liegenden Modelle fortlaufend nachjustiert werden, um belastbare, entscheidungsrelevante Einsichten zu sichern (Rust et al., 2021, S. 21-27). So ermöglichen es KI-gestützte Sentimentanalysen Unternehmen, Social-Media-Inhalte fortlaufend zu justieren, die Markenwahrnehmung nahezu in Echtzeit zu verfolgen und daraus belastbare Maßnahmen abzuleiten.

Demnach eröffnen KI-gestütztes Social Listening und automatisierte Sentiment-Analysen Unternehmen strategische Optionen; jedoch erfordern sie ebenso eine realistische Einschätzung der Grenzen. Branchenspezifische Fachterminologie erschwert hier die Übertragbarkeit vortrainierter Modelle erheblich. Modelle ohne entsprechende Anpassung analysieren Fachbegriffe und ironische Formulierungen häufig falsch, da Sprachmuster zwischen unterschiedlichen Feldern systematisch abweichen (Rostami et al., 2023, S. 11484-11486). Zudem hängt die Aussagekraft der Analysen entscheidend von der Qualität und Abdeckung der zugrunde liegenden Daten ab. Verlässliche Entscheidungen erfordern somit systematische Qualitätsmetriken wie Glaubwürdigkeit, Reputation, Nützlichkeit und Vollständigkeit - ergänzt um iterative Filterprozesse, die fachgebietsbezogenes Wissen integrieren, was allerdings zusätzliche Ressourcen bindet (Aramburu et al., 2024, S. 667-675, 685-689).

Die Leistungskennzahlen von Sentiment-Verfahren variieren je nach Datensatz und Anwendungskontext deutlich; dies macht eine kontinuierliche Validierung, Kalibrierung und menschliche Qualitätskontrolle unerlässlich. Daher sollte die Auswahl und Kombination der Methoden empirisch anhand fachspezifischer Stichproben erfolgen und nicht allein auf Einsetzung von

Standardmodellen setzen (Hartmann et al., 2025, S. 75-79, 83-86). Insgesamt sind KI-gestützte Analysen dann wertstiftend, wenn Unternehmen domänenspezifische Adaptionen vornehmen, transparente Qualitätsprüfungen etablieren und personelle Aufwände für Datenpflege sowie laufende Kontrolle in die Analyseprozesse einplanen (Aramburu et al., 2024, S. 683-689; Hartmann et al., 2023, S. 85-87).

3.1.4 Anwendung von KI im Werbeanzeigenmanagement

Interaktionen beeinflussen die Wahrnehmung von Social-Media-Werbung erheblich. So erhöht die Einblendung von „Likes“ oder Kommentaren die CTR im Durchschnitt um 34 %. Bei Statusgütern kann der relative Anstieg sogar bis zu 270 % betragen. Besonders ausgeprägt sind diese Auswirkungen bezogen auf Bekleidung, Automobilindustrie und Nahrungsmitteln, während sie bei Finanzdienstleistungen und Konsumelektronik weniger stark ausgeprägt sind (Huang et al., 2020, S. 1044-1185).

Generative KI-gestützte Videoanzeigen steigern das Engagement zusätzlich. So erhöhen personalisierte generativ erstellte Videos die Interaktionsraten um 6-9 Prozentpunkte gegenüber statischen Bildanzeigen und generischen Videos, wobei diese Effekte konsistent über Geschlecht und Herkunft hinweg gelten. Durch die Nutzung von Influencer-Empfehlungen oder über generative Personalisierung können sowohl das Engagement als auch Klicks verbessert werden, sofern Format und Inhalte zur Zielgruppe und Produktkategorie passen (Kapoor & Kumar, 2025, S. 733-747). Zentrale Voraussetzung ist hier eine standardisierte Messung. Entsprechend stärkt die wahrgenommene Personalisierung die Markeninteraktion über die Relevanz, zugleich kann daraus auch Anzeigenvermeidung resultieren, wenn die Personalisierung zu eindeutig ist (De Keyzer et al., 2024, S. 1208-1211, 1219-1221).

Daraus ergeben sich Anforderungen an den Einsatz von KI im Werbeanzeigenmanagement. Datenethische Leitlinien und transparente Mechanismen stärken die Wahrnehmung von Relevanz und mindern Überwachungsassoziationen. Dies umfasst die offene Kennzeichnung personalisierter Ausspielungen und eine klare Zweckbindung der Datenverarbeitung. Zusätzlich sind leicht zugängliche Opt-out-Möglichkeiten und Frequenzkontrollen bereitzustellen; die Synchronisierung über Endgeräte sollte zurückhaltend erfolgen. Werden diese Prinzipien missachtet, etwa durch intransparentes Tracking, mehrfach synchronisierte Ausspielungen oder eine weitreichende Weiterverwendung identischer Daten, verstärkt dies die Überwachungswahrnehmung und schwächt Markenbewertungen (De Keyzer et al., 2024, S. 1208-1211, 1219-1221; Segijn et al., 2024, S. 516-519).

Auch die Erstellung und Anpassung von Werbetexten kann durch textanalytische und generative Modelle automatisiert werden. Domain- und Task-adaptives Pretraining verbessert die Klassifikationsleistung systematisch und erhöht damit die inhaltliche Passung von Kampagnentexten (Gururangan et al., 2020, S. 8342-8360). In der Praxis erschweren allerdings informelle Schreibweisen, Slang und Fachterminologie die automatisierte Verarbeitung sozialmedialer Inhalte (Nguyen et al., 2020, S. 9-14). Diese Herausforderungen können mithilfe von iterativer Optimierung und Workflows mit Einbindung von Personen bewältigt werden. Ein im „Journal of Advertising Research" publiziertes Modell des „Generative AI-Integrated Co-Creative Process" zeigt, dass menschliche Kuratierung entlang der Phasen „Ideation", „Validierung" und „Ausführung" die Relevanz und Authentizität KI-generierter Inhalte erhöht und Fehlentscheidungen reduziert (Cui et al., 2025, S. 169-177).

Insgesamt bietet KI im Werbeanzeigenmanagement erhebliche Potenziale, die jedoch nur über hochwertige Daten, gezielte Vorverarbeitung und qualitätssichernde menschliche Kontrolle realisiert werden können (Gururangan et al., 2020, S. 8356-8359; Nguyen et al., 2020, S. 12-13; Cui et al., 2025, S. 171-177).

3.2 Status quo der Praxis

3.2.1 Möglichkeiten der KI-Implementierung

Generative KI eröffnet im Social-Media-Management drei unmittelbare Implementierungsfelder: die skalierte Content-Erstellung, Social Listening mit semantischer Verdichtung und die adaptive Werbeanzeigenoptimierung. Die rasante Diffusion von Large-Language-Modellen (LLM) unterstreicht diesen Handlungsdruck. So wurden im Juli 2025 wöchentlich rund 18 Milliarden Nachrichten an ChatGPT versendet, was etwa 10 % der erwachsenen Weltbevölkerung repräsentiert (Chatterji et al., 2025, S. 1-2). Die Nutzungsstatistik verdeutlicht, dass generative KI nicht mehr nur ein Werkzeug für Experten ist, sondern überall eingesetzt wird.

Während die Gesamtzahl der Nachrichten kontinuierlich wächst, nehmen nicht arbeitsbezogene Interaktionen schneller zu und machen inzwischen über 70 % aller ChatGPT-Nachrichten aus (Chatterji et al., 2025, S. 2). Das bedeutet jedoch nicht, dass generative KI für Marketingzwecke marginal ist: Eine automatisierte Gesprächsklassifikation zeigt, dass nahezu 80 % aller Unterhaltungen in die Kategorien „Practical Guidance", „Seeking Information" und „Writing" fallen. Letzteres ist dabei das dominierende Einsatzfeld bei beruflichen Aufgaben und umfasst neben der automatischen Erstellung auch das Editieren, Übersetzen und Zusammenfassen von Texten (Chatterji et al., 2025, S. 2). Etwa 40 % der arbeitsbezogenen Mitteilungen bezie-

hen sich auf solche Schreibprozesse, und zwei Drittel dieser Mitteilungen ersuchen das Modell, vom Menschen bereitgestellte Inhalte zu verändern (Chatterji et al., 2025, S. 2). Diese Ergebnisse machen deutlich, dass generative Modelle im Marketing insbesondere für Textvarianten, Übersetzungen und kanaladäquate Anpassungen prädestiniert sind.

In der Content-Erstellung können generative Systeme den klassischen Zielkonflikt zwischen Quantität und Qualität verschieben, indem sie Ideation, Variantenbildung, Kanaladaption und sprachliche Lokalisierung beschleunigen. Entsprechend wird KI im Marketing speziell für Social Posts, Produktbeschreibungen und PR-Texte genutzt (Heitmann, 2024, S. 10-12, 15-16). Die skizzierte ChatGPT-Analyse zeigt, dass automatisches Schreiben nicht nur vollständig neue Texte generiert, sondern häufig vorhandene Inhalte überarbeitet und an Tonalität oder Format anpasst (Chatterji et al., 2025, S. 2). Parallel hierzu zeigt sich, dass generative Assistenten besonders Berufseinsteiger produktiver machen, während erfahrene Beschäftigte weniger profitieren (Brynjolfsson et al., 2023, S. 2-4). Diese Beobachtung wird durch ein „Human-in-the-Loop"-Betriebsmodell gestützt, in dem KI Rohfassungen liefert und Fachpersonen finale Qualitäts- und Compliance-Prüfungen vornehmen. Die umfassende Verbreitung generativer Chatbots in der Bevölkerung bestätigt diese doppelte Perspektive; demnach ermöglichen sie eine produktive Unterstützung im professionellen Kontext und erleichtern zugleich private Informations- und Schreibaufgaben (Chatterji et al., 2025, S. 1-2).

Um die genannten Potenziale reproduzierbar ausschöpfen zu können, braucht es systematisches Prompt-Engineering innerhalb eines schlanken Rahmens aus Daten, Prozessen, Tools und Rollen. Bewährt hat sich ein R-A-F-C-Q-Schema, bestehend aus: Rolle (z. B. „Social-Media-Manager"), Aufgabe (konkreten Output-Zielen, Messgrößen), Format (Listen, Tabellen, Längenlimits), Kontext/Constraints (Zielgruppen, Tonalität, rechtlichen Leitplanken, Markenstil) und Qualität (expliziten Evaluationskriterien, z. B. Faktentreue, Zitierstandard, CTA-Klarheit); dies spiegelt sich auch im Vorgehen von Roth et al. (2024) wider. Forschung zu Prompt-Methoden zeigt, dass strukturierte Instruktionen und Beispiele das In-Context-Lernen verbessern (Wei et al., 2022, S. 2-4). Self-Consistency - also das Aggregieren mehrerer gedanklicher Ableitungen - erhöht diesbezüglich die Robustheit bei offenen Entscheidungsproblemen (Wang et al., 2023, S. 1-3). Für interaktive Aufgabenketten kann ReAct-Prompting Reasoning-Schritte (Handlungspläne) mit Tool-Aufrufen verbinden, was Halluzinationsrisiken mitunter senkt bzw. die Nutzbarkeit in Workflows mit Recherche- oder API-Zugriff verbessert (Yao et al., 2022, S. 1-3). In der Praxis werden diese Prinzipien in iterativen Prompt-Zyklen umgesetzt, was sich wie folgt zusammensetzt: eine Basisprompt-Variante erstellen, einen Output entlang der Qualitätskriterien prüfen, Lücken durch zusätzliche Kontext- und Constraint-Angaben

schließen, Varianten gegeneinander testen und die beste Fassung als wiederverwendbares Template versionieren. Dass die Mehrheit der beruflichen ChatGPT-Nutzung „Writing“-Aufgaben abdeckt (Chatterji et al., 2025, S. 2), unterstreicht die Bedeutung eines sauberen Prompt-Frameworks für Textvarianten im Marketing.

3.2.2 Best-Practice-Beispiele Kraft Heinz und L’Oréal

Der Einsatz von KI im Social-Media-Management entwickelt sich zu einem zentralen Hebel, um Prozesse effizienter zu gestalten und die Wirkung digitaler Kommunikation zu steigern. Eine häufig genutzte Anwendung ist die generative Content-Erstellung. So setzte Kraft Heinz in der Kampagne „AI Ketchup“ 2023 das Bildmodell DALL·E 2 ein, um ohne expliziten Markennamen visuelle Ketchup-Motive zu generieren, die dennoch unverkennbar der Marke „Heinz“ zugeordnet werden konnten (Marketing Maverick, 2025). Dabei wurden die KI-generierten Visuals in Social-Media-Kampagnen integriert und durch erstellte KI-Bilder ergänzt. Die Kampagne erzielte weltweit mehr als 850 Millionen Earned-Media-Impressionen, lag bei der Social-Media-Interaktionsrate 38 % über früheren Kampagnen und erreichte laut Fallstudie einen Return on Investment von rund 2500 %. Damit zeigt sich, dass generative KI die Content-Erstellung beschleunigen, Kosten senken und die Wirksamkeit von Kampagnen steigern kann (Geitz, 2025; Marketing Maverick, 2025). Parallel dazu entwickelte Kraft Heinz die interne Plattform „TasteMaker“, die als Retrieval-Augmented-Generation-System arbeitet und die Produktion von Bildern sowie von Marketing-Visuals stark beschleunigt. Durch den Einsatz generativer Modelle wird die Erstellung und Personalisierung von Inhalten, die zuvor mehrere Wochen beanspruchte, auf wenige Stunden reduziert. So sinkt die Time-to-Market von acht Wochen auf acht Stunden, was wiederum Kreativteams entlastet und eine konsistente Markenpräsenz über zahlreiche digitale Kanäle hinweg ermöglicht (Geitz, 2025; Marketing Maverick, 2025).

Auch im Werbeanzeigenmanagement führt KI zu messbaren Effizienzgewinnen. Diesbezüglich investiert L’Oréal mittlerweile mehr als 60 % seines digitalen Mediabudgets in soziale Netzwerke und nutzt seit 2023 das KI-Tool Tidal, um die Aussteuerung von Kampagnen automatisiert zu optimieren. Zudem wendet das Unternehmen generative Modelle wie Imagen 3 und Gemini in seinem „CREAITECH“-Labor an, um lokale Kampagnenassets aus einfachen Texteingaben zu erzeugen. Diese Technologien beschleunigen die Erstellung und Lokalisierung von Kampagnen erheblich. Entsprechend können nun Marketingmaßnahmen, die früher Wochen dauerten, binnen Stunden realisiert werden. Visuals können dabei an über 20 Märkte angepasst werden (Zwieglinska, 2025). L’Oréal berichtete, dass ein Testlauf in den nordischen Ländern 2023 die Mediaeffizienz um 22 % und die Kampagneneffektivität um 14 % steigerte

(Zwieglinska, 2025). Damit erreichte das Unternehmen mehr Wirkung je eingesetztem Werbe-Euro, ohne das Budget zu erhöhen. Diesbezüglich betonen die Verantwortlichen jedoch, dass es nicht darum gehe, mehr Geld auszugeben, sondern vorhandene Mittel effizienter einzusetzen (Zwieglinska, 2025).

Die aufgeführten Beispiele verdeutlichen, wie datengestützte Automatisierung und generative KI im Social-Media-Management zu einer schnelleren Content-Produktion, präziserem Targeting und einer höheren Investitionsrendite führen können.

3.2.3 Herausforderungen und Grenzen der KI-Implementierung

Eine zentrale Implementierungsbarriere generativer KI in der Content-Produktion liegt in mangelhafter Datenqualität und fragmentierten Datensilos. Wirksame Textgenerierung erfordert über den gesamten Datenlebenszyklus konsistente, strukturierte und zugängliche Informationen. Ohne stabile Datenpipelines und gepflegte Validierungsdatensätze scheitern entsprechende Projekte oft an fehlender Qualität und inkonsistenter Infrastruktur (Haefner et al., 2023, S. 3-4). Gerade kleine und mittlere Unternehmen leiden unter heterogenen Quellsystemen und unzureichenden Datenmanagementpraktiken. Dies führt einerseits zu signifikanten Verzerrungen in den Analysen und reduziert andererseits die Conversion-Rates KI-gestützter Werbeanzeigen um bis zu 20 % (Schwaeke et al., 2024, S. 1308). Forschung zu Feature Engineering zeigt indes, dass Merkmale wie Rauschen, fehlende Werte und Ausreißer die Modellleistung beeinträchtigen und dass eine robuste Datenbereinigung unerlässlich ist. Hierbei lässt sich eine Verbesserung durch zentrale Datenplattformen und klare Data-Governance-Strukturen erzielen. Standardisierte Prozesse erhöhen die systematische Versionierung und die Nachvollziehbarkeit von Trainingsdaten. Dies steigert dann die Modellqualität, senkt Fehlerquoten in Klassifikationsaufgaben um rund 15 % und erleichtert zugleich die Automatisierung der Datenzuordnung (Papagiannidis et al., 2023, S. 124).

Neben technischen Voraussetzungen sind fehlende Kompetenzen und unzureichendes Change-Management zentrale Hemmnisse für die KI-Einführung im Marketing. Sobald demnach der anfängliche Hype nachlässt, können mangelndes Verständnis der Technologie und fehlende Schulungen häufig in fehlerhaften Anwendungen resultieren. Eine repräsentative Befragung von 2000 Beschäftigten durch PwC in Deutschland zeigt, dass nur 28 % bereits Schulungen zu generativer KI absolviert haben. Mitarbeitende in Marketing und Vertrieb verfügen im Vergleich zu jenen aus der IT entsprechend seltener über fundierte Kenntnisse. Hierbei schätzen 61-67 % der Mitarbeitenden den künftigen Bedarf an KI-Kompetenzen als hoch ein

(PwC Deutschland, 2024, S. 27-33). Dabei bildet der Kompetenzmangel nicht nur ein technologisches, sondern auch organisatorisches Problem. Nur rund 33 % der befragten Unternehmen legen Wert auf Investitionen in Mitarbeiterschulungen. Wiederum 35 % nennen Fachkräftemangel und 27 % fehlendes Vertrauen als Hürden (IFH KÖLN/ECC Köln, 2025, S. 1-2). Systematische Reviews empfehlen insbesondere für kleine und mittlere Unternehmen den Aufbau einer Lernkultur, transparente Kommunikation und sichtbare Führungseinbindung als Erfolgsfaktoren für die Einführung von KI (Schwaeke et al., 2024, S. 1316-1317).

Des Weiteren erschweren technische und organisatorische Barrieren die Integration neuer Modelle, insbesondere wenn KI-Lösungen mit heterogenen Altsystemen und fragmentierten Analyseprozessen verzahnt werden sollen. So können Kompatibilitätsprobleme zwischen KI-Werkzeugen und bestehender IT-Architektur dazu führen, dass Potenziale ungenutzt bleiben. In prozessorientierten Branchen mit sicherheitskritischen Anlagen verlängern Schnittstellen- und Compliance-Aufwände die Einführungszeit und erhöhen die Integrationskosten (Weber et al., 2022, S. 1554-1558). Diesbezüglich zeigt eine Marktstudie der IHF Köln, dass 31 % der befragten Unternehmen die Integration von Daten in bestehende Systeme als zentrale Hürde benennen (IFH KÖLN/ECC KÖLN, 2025, S. 1). Unternehmen sollten daher flexible Middleware-Lösungen, standardisierte Schnittstellen sowie ein belastbares API- und Metadaten-Management priorisieren. Demnach erlaubt nur eine modular aufgebaute Systemarchitektur, Daten- und Softwarestandards konsistent durchzusetzen und KI-Services skalierbar in Kernprozesse einzubetten (Weber et al., 2022, S. 1550-1552).

Schließlich zählen algorithmische Verzerrungen und die Gefahr kreativer Homogenisierung zu den zentralen Risiken beim Einsatz generativer KI in der Werbemittelerstellung. Auslieferungsalgorithmen können demografische Schieflagen verstärken, die nicht aus dem Targeting der Werbetreibenden resultieren. Daher werden A/B-Tests und systematische Korrekturen zur Vermeidung von Attributionsfehlern empfohlen (Imana et al., 2025, S. 2601-2603). Ein weiterer Schwachpunkt der KI-Systeme liegt in der Hate-Speech-Erkennung. Gängige Transformer-Modelle bestimmen Formen wie negierte Hassäußerungen und Reclaimed Slurs falsch und weisen Genauigkeitslücken auf (Röttger et al., 2021, S. 41-58).

Darüber hinaus steigert generative KI zwar die individuelle Kreativität von Texten, reduziert aber die kollektive Neuartigkeit und Varianz der Outputs um bis zu 17 % (Doshi & Hauser, 2024, S. 3-6). Rekursives Training auf synthetisch erzeugten Inhalten führt zudem zu einem Model Collapse. Dann schrumpft die Verteilungsvarianz, Randfälle gehen verloren, und die Ergebnisvielfalt sinkt messbar um bis zu 30 %. Nur ein stabiler Anteil echt-menschlicher

Daten und kontinuierliche Qualitätskontrollen können diese Effekte begrenzen (Shumailov et al., 2024, S. 755-759).

Kreativteams sollten deshalb als verpflichtende „Human-in-the-Loop“-Instanz in den KI-gestützten Anzeigenprozess integriert werden - ergänzt durch kuratierte Prompt-Leitfäden, Diversität-Checks und regelmäßige Überprüfung der Auslieferung. Parallel dazu sind Datenmanagement-Strategien nötig, die Trainings- und Referenzdaten diversifizieren und synthetische Rückkopplungen begrenzen, um Verzerrungen und kreative Eintönigkeit nachhaltig zu vermeiden (Imana et al., 2025, S. 2601-2603; Shumailov et al., 2024, S. 755-759).

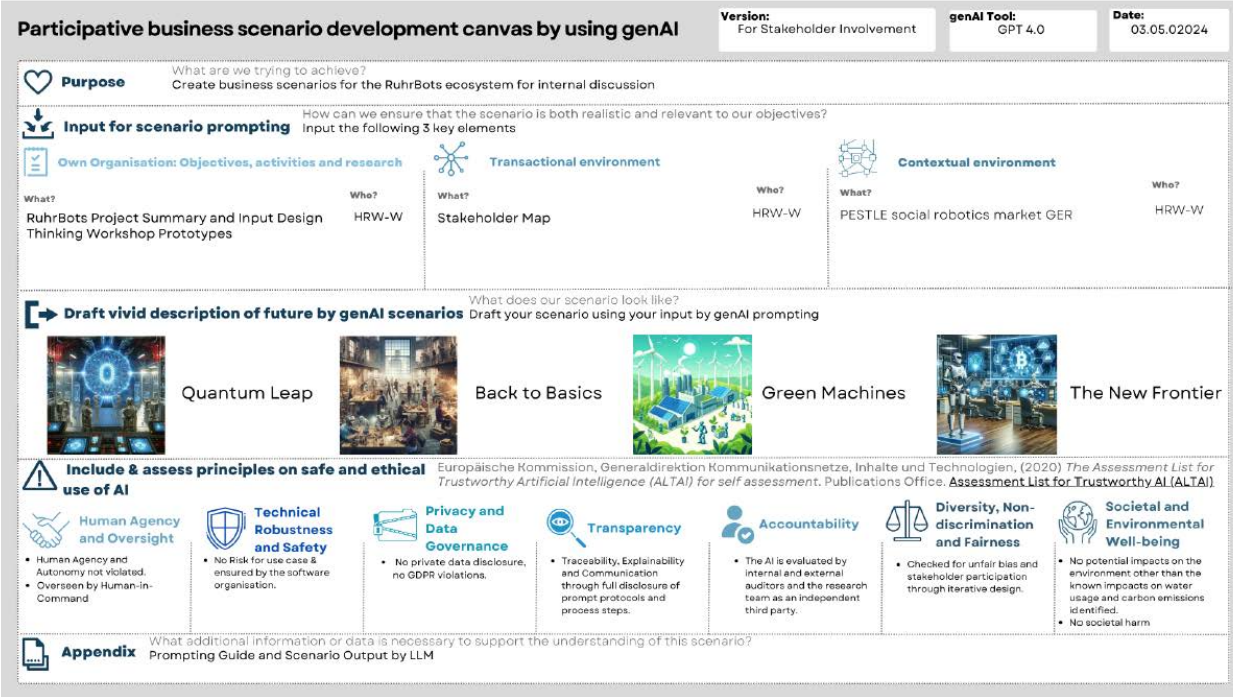

Abbildung 1: Participative Business Scenario development canvas by using genAI, Quelle: Roth et al. (2024, S. 530).

Das KI-Prompting kann nach dem Canvas „Appendix B Prompting Canvas“ von Roth et al. (2024, S. 530) dokumentiert werden. Dieses dient dazu, KI-gestützte Szenarienentwicklung systematisch zu planen und das Prompting nachvollziehbar zu dokumentieren: Dabei strukturiert der obere Bereich Zweck und Eingaben für Prompts (Ziele der Organisation, Stakeholder, transaktionale und kontextuelle Umweltfaktoren); der Mittelteil hält die mithilfe von LLMs generierten, lebendigen Szenariobeschreibungen in Varianten fest; der untere Bereich verankert Prüfkriterien für sicheren sowie ethisch verantwortbaren KI-Einsatz (u. a. Transparenz, Daten-Governance, Accountability). Dadurch fungiert das Canvas als methodisches Protokoll:

Prompt-Inhalte, Annahmen und Evaluationskriterien werden somit versionierbar, prüfbar und für Workshops bzw. Strategiedokumente reproduzierbar (Roth et al., 2024, S. 530).

3.3 Caramba

3.3.1 Unternehmensprofil und Geschäftsmodell

Caramba wurde 1903 von Max Elb in Dresden gegründet. Prägend für das Unternehmen waren die frühe Spezialisierung auf chemische Spezialprodukte wie Rostlöser und Multiöle sowie die sukzessive Ausweitung auf Reinigung, Pflege und Wartung. Bis heute versteht die Markenidentität von Caramba sich als Problemlöser für private und industrielle Anwendungen. Im Jahr 2004 wurde die Marke in der Reihe „Marken des Jahrhunderts“ geführt, was die kulturelle Verankerung und Reputation zusätzlich sichtbar machte (Caramba GmbH, 2025). Vor diesem Hintergrund lässt sich Carambas aktuelle Positionierung als qualitätsorientierte Traditionsmarke mit breitem Anwendungsspektrum konsistent ableiten. Dies geht hervor aus der historischen Problemlöser-Logik, der Portfolioerweiterung in Reinigung, Pflege und Wartung sowie der evidenzbasierten Wirkung von Markenerbe und Authentizität auf Vertrauen, Loyalität und Kaufabsicht (Caramba GmbH, 2025).

Durch den Management-Buy-out (MBO) zum 1. September 2024 hat sich Caramba aus der Konzernbindung der Berner Gruppe gelöst und als inhabergeführtes Unternehmen strategische Autonomie zurückgewonnen. Damit verbunden sind schnellere Entscheidungen und umfassendere Handlungsspielräume (Crowe BPG, 2024; CHEManager, 2024). In einem Verbandsinterview betonte der geschäftsführende Gesellschafter Reiner Eckhardt, dass nach dem Eigentümerwechsel keine Konzernrichtlinien und kein Konzernberichtswesen mehr gelten, was die Organisation insgesamt agiler macht. Diese Änderung in der Firmenpolitik schafft die Voraussetzung, digitale Lösungen - etwa im Social-Media-Management - zügiger zu pilotieren (Unternehmerverband, 2024).

Das aktuelle Geschäftsmodell spricht zwei deutlich differenzierte Märkte an: Privatkunden mit einer Consumer Line (B2C) sowie gewerbliche und industrielle Anwender mit professionellen Sortimenten (B2B). Beide Segmente werden auf der Unternehmensseite getrennt geführt und durch technische Dokumente wie Sicherheitsdatenblätter unterstützt; dadurch werden wiederum differenzierte Kommunikations- und Informationsbedarfe notwendig (Caramba GmbH, 2025). Für Verbraucher sind praktische Anwendungen entscheidend, während Geschäftskunden umfassende Produkt- und Anwendungsinformationen erwarten. Die organisatorische Entflechtung seit dem MBO erleichtert es Caramba, diese duale Ausrichtung mit datenbasierten,

digital gestützten Marketing- und Contentprozessen zielgruppenspezifisch auszugestalten (Caramba GmbH, 2025; Unternehmerverband, 2024).

3.3.2 Instagram - Social-Media-Audit Caramba

KPIs Zeitraum: 28.09.24-28.09.25	Feed (Σ / x̃ / Ø)	Reels (Σ / x̃ / Ø)	Kurzbefund
Publikationsmenge	Σ 80 Posts	Σ 73 Reels	Volumen vergleichbar, Feed leicht häufiger genutzt; kein deutliches Ungleichgewicht zwischen Formaten.
Reichweite	Σ 84 965 x̃ 991 Ø 1 062	Σ 106 576 x̃ 1256 Ø 1 460	Reels generieren 25,44 % mehr Reichweite als Feed-Posts, wobei der Median die größere Reichweitenspanne zeigt.
Interaktionen	Σ 3 182 x̃ 37 Ø 39,8	Σ 3 992 x̃ 644 Ø 54,7	Reels erzielen pro Beitrag mehr Reaktionen; Feed-Posts liegen beim Median knapp dahinter.
Engagementrate (Interaktionen/ Reichweite)	x̃ 3,84 % Ø 3,92 %	x̃ 3,34 % Ø 3,83 %	Feed zeigt einen leicht höheren Median der Engagementrate, während Reels im Durchschnitt fast gleichauf liegen.
Formatvergleich	-	-	Reels liefern höhere Reichweite und Interaktionen pro Beitrag; Feed erreicht leicht höhere mediane Engagementrate - Potenzial, Formatrollen zu schärfen.
Tracking/Attribution	-	-	Es fehlen belastbare Website- oder Kaufdaten; weder UTM-Parameter

			noch Conversion-Tracking sind implementiert, sodass Attribution entlang des Funnel nicht möglich ist.
Commerce-Nutzung	-	-	Shopping-Features (Produktmarkierungen, Shop-Tab) und Calls-to-Action werden kaum genutzt, was die kanalübergreifende Monetarisierung einschränkt.
Ziele/KPIs	-	-	Markenbekanntheit und Community-Aufbau sind als allgemeine Ziele vorhanden, jedoch ohne Soll-KPIs; gemessen werden Follower, Reichweite, Impressionen und Interaktionen.
Prozesse/ Governance	-	-	Die Betreuung liegt bei einer einzelnen Person; es existieren keine dokumentierten Prozesse, Guidelines oder Eskalationsschemata; ein Dashboard ohne verbindliche Workflows unterstützt die Arbeit.

Tabelle 1: Instagram-Audit Caramba, Quelle: Eigene Darstellung in Anlehnung an Reinecke & Klautzsch (2013), S. 123

Das vorliegende Instagram-Audit (Tabelle 1) aus dem Zeitraum 28.09.2024 bis 28.09.2025 folgte der Logik eines Social-Media-Audit. Ziel war es, Messgrößen, Prozesse und Verantwortlichkeiten systematisch verknüpft darzustellen und deren Konsistenz zu überprüfen. Dabei waren Kennzahlen aus den Kommunikationszielen abzuleiten und in einem konsistenten Steuerungsrahmen zu verankern (Reinecke & Klautzsch, 2013, S. 108-123) (Anhang 3).

Im Sinne dieses Audit-Verständnisses markieren die erhobenen Kennzahlen eine klare Formatdifferenzierung: Reels erzielen mit 106 576 Gesamtreichweite und einem Mittelwert von 1460 eine höhere Reichweitenleistung als Feed-Posts (84965; Ø 1062), während die Interaktionen pro Beitrag zugunsten der Reels ausfallen (Ø 54,7 vs. Ø 39,8). Gleichzeitig liegt der

Median der Engagementrate beim Feed leicht über jenem der Reels (3,84 % vs. 3,34 %) - ein Hinweis auf die unterschiedlichen Wirkmechanismen der Formate. Reels skalieren Reichweite und Interaktionsvolumen stärker; der Feed begünstigt relativ konsistentes Engagement in der Mitte der Verteilung. Für ein Audit impliziert dies die Notwendigkeit einer Formatrollen-Definition entlang von Ziel- und Wirklogiken, anstatt eine uniforme Erfolgsmessung über Formate hinweg vorzunehmen (Reinecke & Klautzsch, 2013, S. 123).

Aus Zielsetzungs- und Steuerungsperspektive sind die strategischen Oberziele „Markenbekanntheit“ und „Community-Aufbau“ zwar benannt, jedoch fehlen Soll-KPI-Vorgaben sowie klare Ableitungen in operative Steuerungsgrößen. Im Sinne eines Audits entsteht dadurch eine Ziel-Mess-Lücke. Quantifizierte Sollwerte für Reichweite, Impressionen, Interaktionen oder Engagement sind demnach nötig, um Abweichungen belastbar zu interpretieren, Prioritäten kapazitäts- und budgetseitig abzubilden und Lernzyklen systematisch zu schließen. Reinecke und Klautzsch betonen in diesem Zusammenhang, dass Kennzahlen aus den Zielen abzuleiten und in einer Audit-Checkliste konsistent zu verankern sind; dies dient dazu, die Wirksamkeit von Maßnahmen zu prüfen und eine nachvollziehbare Erfolgskontrolle zu ermöglichen (Reinecke & Klautzsch, 2013, S. 108-123). Vor diesem Hintergrund bleibt unklar, ob der beobachtete Reichweitenvorteil der Reels (25,44 %) tatsächlich dem Primärziel ‚Bekanntheit‘ optimal dient oder ob flankierende Zielgrößen - etwa zur Community-Qualität - gesondert gewichtet werden sollten. Ohne Ziel-Gewichtungen und Schwellenwerte ist die Bewertung von Unterschieden zwischen Reichweite und Engagement strukturell unterbestimmt (Reinecke & Klautzsch, 2013, S. 123).

Die Mess- und Attributionslage weist überdies eine zentrale Schwäche auf. So existieren keine belastbaren Website- oder Kaufdaten aus Instagram, da UTM-Parameter und Conversion-Tracking fehlen. Aus Audit-Sicht verhindert dies die Prüfung der Ziel-Mittel-Kette zwischen Social-Kontakt, Traffic-Transfer und nachgelagerter Wirkung. Dies wiederum erschwert die Beantwortung der Frage, ob Reichweite und Interaktionen über den Plattformrand hinaus ökonomisch oder verhaltensbezogen anschlussfähig sind.

Ein Audit verlangt die explizite Verbindung von Zielen, Formaten, Zielgruppen und KPIs in einem konsistenten Steuerungsmodell. Dieses Modell sollte entsprechend sowohl die Skalierung als auch die Qualität der Zielerreichung abbilden und dabei periodisch überprüft werden (Reinecke & Klautzsch, 2013, S. 108-123). Solange diese Brücke fehlt, verbleibt die Steuerung auf Plattform-Proxys. Zudem bleibt die Aussagekraft für Zielbeiträge jenseits des Kanals eingeschränkt. In die gleiche Richtung deutet die eingeschränkte Nutzung von Shopping-Funkti-

onen, Produktmarkierungen, Shop-Tabs und klaren Handlungsaufforderungen. Ohne konsistente Commerce-Routen fehlen standardisierte Übergänge in konversionsnahe Umgebungen, die in einem Audit als obligatorische Prozessbausteine zu prüfen wären (Reinecke & Klautzsch, 2013, S. 123).

Organisatorisch ist die Betreuung durch eine Einzelperson bei fehlenden dokumentierten Prozessen, Guidelines und Eskalationsschemata kritisch (Anhang 37). Ein Audit adressiert ausdrücklich die Governance-Dimension, da Qualitätssicherung, Krisenkommunikation, Rollen, Verantwortlichkeiten und Freigabeprozesse Prüffelder darstellen (Reinecke & Klautzsch, 2013, S. 108-123). Das Fehlen eines verbindlichen Workflows, von Checklisten und einem operativ genutzten Dashboard schwächt die Reproduzierbarkeit und das Risikomanagement der Social-Media-Arbeit. Ohne klaren Redaktionsprozess, definierte Review-Zyklen und Eskalationslogik drohen inkonsistente Tonalität, reaktive statt proaktive Community-Bearbeitung und ineffiziente Ressourcennutzung. In einem Audit wäre hier zu prüfen, inwieweit Planungs-, Veröffentlichungs-, Moderations- und Reportingprozesse standardisiert, dokumentiert und personenunabhängig tragfähig sind; die aktuelle Lage deutet auf eine Abhängigkeit von implizitem Wissen und Ad-hoc-Entscheidungen hin (Reinecke & Klautzsch, 2013, S. 123).

Inhaltlich und formatstrategisch zeigen die Daten sowohl eine klare Reels-Stärke in Reichweite und Interaktionsvolumen als auch einen leichten Feed-Vorteil im Median-Engagement. Ohne strategisch definierte Formatrollen und messbare Soll-Beiträge zu den Oberzielen bleibt indes unklar, wie Ressourcen zwischen Reichweiten- und Engagementzielen zu allokieren sind. Entsprechend verlangt ein Audit die explizite Verbindung von Zielen, Formaten, Zielgruppen und KPIs in einem konsistenten Steuerungsmodell, das sowohl die Skalierung als auch die Qualität der Zielerreichung abbildet und periodisch überprüft wird (Reinecke & Klautzsch, 2013, S. 108-123). Dies umfasst auch die Systematik, mit der Formate nach Leistungsprofilen eingesetzt und entlang eines Redaktionsplans aufeinander bezogen werden. Ein Beispiel dafür sind Reels für Reichweitenaufbau und Feed-Karussells für Engagement-Vertiefung - jeweils mit dokumentierten Sollwerten und KPIs (Reinecke & Klautzsch, 2013, S. 123). In Summe ergeben sich vier aktuelle Herausforderungslinien:

1) Fehlende Ziel-Operationalisierung in mess- und steuerbare Soll-KPIs.
2) Unzureichende Mess- und Attributionskette über die Plattform hinaus.
3) Nicht genutzte Commerce-Funktionen als Standard-Übergänge in konversionsnahe Umgebungen.

4) Fragile Governance mit Einzelverantwortung, fehlenden Prozessen und nicht institutionalisiertem Dashboard-Einsatz.

Eine sachliche Brücke zu potenziellen KI-Anwendungen ergibt sich dort, wo datengetriebene Automatisierung Mess- und Prozesslücken schließt. Perspektivisch kann KI die Ableitung format- und zielgruppenspezifischer Soll-KPIs unterstützen und Content- sowie Community-Prozesse regelbasiert stabilisieren; dies setzt zuvor jedoch eine auditkonforme Daten- und Governance-Basis voraus.

4 Empirische Analyse mithilfe von A/B-Test am Beispiel von Caramba

4.1 Methodisches Vorgehen zur KI-Integration

4.1.1 Zielsetzung des A/B-Tests im Meta-Werbeanzeigenmanager

Ziel des Experiments ist die kausale Prüfung, ob generativ mit KI erstellte Werbemittel im Meta-Werbeanzeigenmanager unter identischen Rahmenbedingungen effizienter ausliefern als herkömmliche Creatives. Die Zuweisung erfolgt hierbei personenbasiert und persistent in zwei zufällige, nicht überlappende Gruppen, sodass jede Person während des gesamten Testhorizonts nur eine Variante sieht. Dafür teilt die Meta-Experiments-Funktion die Zielgruppen randomisiert und nicht überlappend (Kohavi et al., 2020, S. 6-7; Meta Business Help Center, o. D., (A)).

Das Messfenster beginnt erst nach Abschluss der Lernphase. In der Lernphase stabilisiert die Auslieferungslogik ihre Schätzung; Metriken aus dieser Phase dienen folglich der Rekrutierung von Usern, nicht der Evaluation der Testergebnisse. Die Lernphase wird gemäß Plattformlogik und den vorgesehenen Indikatoren dokumentiert. Relevante, als „signifikant“ definierte Bearbeitungen, die ein erneutes Lernen auslösen, sind vom Messfenster ausgeschlossen (Meta Business Help Center, o. D. (C, D)). Die Attribution wird vorab auf die Frequency „eine Ansicht innerhalb von sieben Tagen“ fixiert. Diese Frequency wird im Reporting festgehalten; abweichende Attributionsfenster werden nicht exploriert. Die gewählte Einstellung steuert sowohl die Berichterstattung als auch das Lernsignal der Auslieferungslogik (Meta Business Help Center, o. D. (E, H)).

Die Integration generativer KI ins Werbeanzeigenmanagement erfordert ein methodisch fundiertes Framework, das sowohl die wissenschaftlichen Standards des Experimentierens erfüllt als auch rechtliche und ethische Anforderungen berücksichtigt. Ziel ist ein reproduzierbares Vorgehen, mit dem KI-gestützte Werbemittel im Meta-Werbeanzeigenmanager fair gegen herkömmliche Creatives getestet werden können. Methodischer Bezugspunkt sind kontrollierte Online-Experimente mit strikter Randomisierung, Konstanthaltung nicht untersuchter Variablen und transparent dokumentierten Abläufen (Kohavi et al., 2020, S. 7-9).

Das Framework folgt vier Leitlinien:

1) **Hypothesenbildung:** Unter identischen Targeting-, Platzierungs- und Budgetbedingungen im Meta-Werbeanzeigenmanager erzielen generativ mit KI erstellte Werbeanzeigen (Text- und Bild-Creatives) eine höhere Reichweite pro Budgeteinheit. Die Hypothese wird operationalisiert durch niedrigere Kosten pro tausend Impressionen (CPM) im Vergleich

zu konventionell von Menschen gestalteten Werbeanzeigen. Die zu prüfende Fragestellung und primären Endpunkte werden vor Testbeginn schriftlich fixiert, um Flexibilitätsbias und selektive Berichterstattung zu vermeiden (Kohavi et al., 2020, S. 7-9).

2) **Die Randomisierung wird auf Anzeigenebene vorgenommen:** Hierbei stellen persistente Zuteilungen sicher, dass jede Person während der Testdauer stets die gleiche Variante sieht und Störungen durch wiederholte Ausspielungen vermieden werden (Gordon et al., 2019, S. 194-198).

3) **Targeting-Parameter, Platzierungen, Bidding-Strategien und Ausspielzeitraum werden konstant gehalten:** Diesbezüglich bildet die Creative-Variante den alleinigen Stimulus. Andere Unterschiede würden die Kausalität verfälschen (Kohavi et al., 2020, S. 7-9).

4) **Das Framework berücksichtigt rechtliche und ethische Vorgaben:** Datenschutz, Urheberrecht, Markensicherheit und eine verantwortungsvolle Nutzung von KI müssen in jedem Experiment eingehalten werden (Mühlhoff & Willem, 2023, S. 2-5).

Überdies sind identische Zeiträume, Placements, Gebotsstrategien und Budgetkorridore zwingend: Das Kampagnenziel ist „Awareness“ mit Optimierung auf Reichweite; die Zielregion ist Deutschland, das Budget pro Arm beträgt 250 Euro bei einer Laufzeit von sieben Tagen (Kohavi et al., 2020, S. 3-7, 22-24).

In einer zweiten Phase wird ein weiterer A/B-Test nach dem gleichen Vorgehen durchgeführt. Dieser Test unterscheidet sich dahingehend, dass auf der Grafik und in den Texten der Hinweis „Mit KI generiert.“ vermerkt wird. Hiermit soll untersucht werden, ob das Verweisen auf die KI-Generierung einen positiven Einfluss auf die Ergebnisse der Werbeanzeigen hat.

4.1.2 Auswahl der KI-Tools und -Modelle

Die Auswahl der KI-Tools bestimmt, welche Stimuli später im Meta-Werbeanzeigenmanager als Varianten gegeneinander getestet werden. Dies folgt methodischen Kriterien, die Reproduzierbarkeit, Messbarkeit, Integrationsfähigkeit sowie rechtliche und markensicherheitsbezogene Anforderungen adressieren. Ausgangspunkt sind Standards kontrollierter Online-Experimente: Varianten werden demnach randomisiert zugewiesen, alle übrigen Einstellungen konstant gehalten und der Stimulus eindeutig dokumentiert (Kohavi et al., 2007, S. 959-962, 965-967). Daraus ergeben sich fünf Auswahldimensionen:

Reproduzierbarkeit als Basiskondition: In der ML-Forschung wird gefordert, dass Daten, Verfahren und Konfigurationen dokumentiert werden, sodass identische Durchläufe möglich sind. Fehlende Dokumentation ist ein Hauptgrund für Replikationsprobleme (Pineau et al.,

2021, S. 1-3, 8-12). Für generative Tools bedeutet dies, dass Modell- und Versionsstände, Sampling-Parameter, Prompts, Seeds sowie Zeitstempel in einem „Creative-Protokoll“ erfasst werden müssen. Transparenzstandards wie Model Cards (Mitchell et al., 2019, S. 220-224, 227-229) und Datasheets for Datasets (Gebru et al., 2021, S. 86-90, 91-92) liefern hierfür strukturierte Felder. Diese umfassen etwa Angaben zu Trainingsdaten, bekannten Risiken, Evaluationsmaßen und zulässigen Nutzungen.

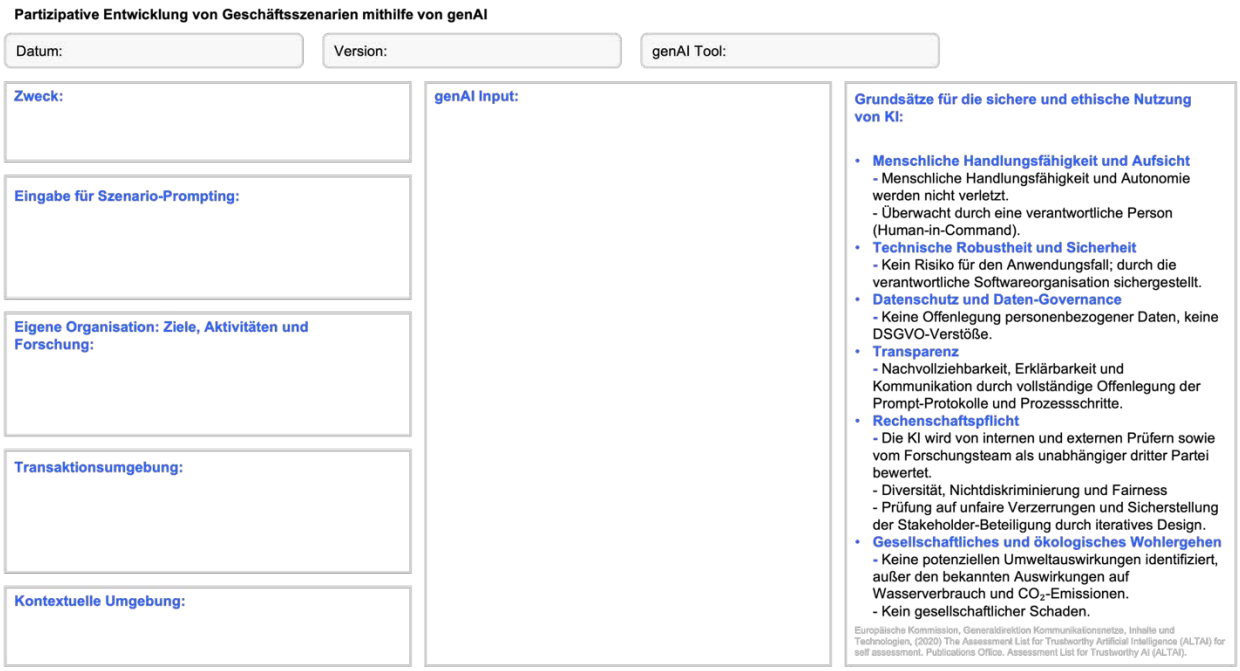

Abbildung 2: Partizipative Entwicklung von Geschäftsszenarien mithilfe von genAI, Quelle: Eigene Darstellung in Anlehnung an Roth et al. (2024, S. 530).

Die Vorgehensweise des Prompting wird nach dem Schema von Roth et al. (2024, S. 530) dokumentiert; hierdurch wird eine zum Teil mögliche Reproduzierbarkeit gewährleistet. Auch wenn die Ergebnisse unterschiedlich ausgegeben würden, können die eingegebenen Prompts reproduziert werden.

Für den regulatorischen Rahmen ist zudem die Kennzeichnungspflicht für synthetische Inhalte relevant: Das EU-AI-Gesetz verlangt, dass Anbieter von Systemen, die synthetische Audio-, Bild- oder Textinhalte erzeugen, Ausgaben in maschinenlesbarer Form erkennbar machen und als künstlich generiert bzw. manipuliert kennzeichnen; dies gilt insbesondere bei Veröffentlichungen gegenüber der Öffentlichkeit (Europäische Union, 2024, Art. 50, S. 82-83). Jedoch kann eine volle Reproduzierbarkeit bei den A/B-Tests nicht gewährleistet werden, da die Generierung durch KI hinsichtlich Grafiken und Text je Anfrage variiert.

Auf dieser Grundlage erfolgt die werkzeugspezifische Bewertung: Für textbasierte Varianten wird ein LLM der GPT-5-Klasse berücksichtigt, da OpenAI für die GPT-Modelle eine paginierte System Card mit Angaben zu Modellmodalitäten, Evaluations- und Sicherheitsmaßnahmen sowie Restrisiken bereitstellt (OpenAI, 2024, S. 1-2, 10-12). Methodisch dafür spricht die API-Verfügbarkeit und damit die Möglichkeit, Prompts, Parameter und Ausgaben versionssicher zu protokollieren. Zugleich erfordert die im Systembericht adressierte Möglichkeit fehlerhafter Angaben, wodurch eine obligatorische „Human-in-the-Loop"-Prüfung vor Einsatz als Anzeigen-Creative erforderlich ist (OpenAI, 2024, 11-12). Für Bild- und Video-Assets wird Adobe Firefly einbezogen, da das unternehmensseitige Fact Sheet technische Datenflüsse, Speicherorte, Inhaltsnachweise („Content Credentials") sowie insbesondere die Trennung von Unternehmensinhalten und Training der Foundation-Modelle im Enterprise-Kontext dokumentiert. Eingaben und Ausgaben werden nachvollziehbar gespeichert, Enterprise-Inhalte werden standardmäßig nicht zum Modelltraining verwendet, und für bestimmte Workflows ist eine IP-Identifizierung vorgesehen (Adobe, 2025, S. 1-5, 7). Diese Kombination aus Kennzeichnung und dokumentierter Datenverarbeitung erleichtert sowohl die Reproduktion von Creatives als auch die rechtssichere Nutzung in Kampagnen.

Komplementär wirkt Meta Advantage+ Creative als integrierte Varianten-Automatisierung, die es zu vermeiden gilt. Für den A/B-Test ist vielmehr die Steuerbarkeit des Stimulus zentral. Da plattforminterne Generierungs- und Modifikationslogiken typischerweise nicht in Form öffentlich begutachteter Model Datasheets vorliegen, ist die Variante vor Testbeginn als statisches Asset zu „fixieren" und zu versionieren; nur so bleibt die Unabhängigkeit der Testvariable gewahrt (Kohavi et al., 2007, S. 961-966; Mitchell et al., 2019, S. 222-225).

Wiederum wird die **Integrationsfähigkeit** entlang eines einheitlichen Prozessschemas bewertet: Für GPT-5 ist die Textgenerierung über API bzw. Export möglich, die resultierenden Kopien werden als einzelne Anzeigen-Creatives in den Werbeanzeigenmanager geladen. Für Adobe Firefly sind Bild-/Video-Assets über Exportpfade mit verifizierbaren Content Credentials verfügbar, wobei diese die Erfüllung der Transparenzpflichten nach Art. 50 AI-Act unterstützen (Adobe, 2025, S. 5; Europäische Union, 2024, Art. 50, S. 82-83). Advantage+ Creative wird - sofern es für ergänzende Varianten genutzt wird - vor dem Testlauf „eingefroren"; demnach wird die automatisch erzeugte Fassung als Datei exportiert und mit einer ID hinterlegt. Dynamische, während der Laufzeit variierende Enhancements sind im strikten A/B-Design zu vermeiden, um Confounding zu verhindern (Kohavi et al., 2007, S. 963-967).

Messbarkeit und **Governance** werden durch ein Protokoll-Set abgesichert, das sich aus folgenden Schritten zusammensetzt: Vorabdefinition von Hypothesen und Stimulus-Attributen,

Creative-Protokolle mit Modell- und Prompt-Versionen, Speicherung der Ausgaben samt Content Credentials und Compliance-Checks (Mitchell et al., 2019, S. 222-228; Gebru et al., 2021, S. 86-91).

Schließlich werden **rechtliche Anforderungen** operationalisiert: Generierte Inhalte werden somit erkennbar gekennzeichnet, urheber- und lizenzrechtliche Rahmenbedingungen je Tool geprüft und personenbezogene Daten nicht für Modelltraining genutzt. Entsprechend werden die Kennzeichnungspflichten aus Art. 50 AI-Act in die Produktions- und Veröffentlichungsroutine integriert (Europäische Union, 2024, Art. 50, 82-83; Adobe, 2025, S. 3-5).

In Summe werden GPT-5 (Text), Adobe Firefly (Bild/Video) und Advantage+ Creative (plattformnahe Ergänzungsvariante) unter der Maßgabe eingesetzt, dass Stimuli stabil versioniert, transparent dokumentiert und rechtlich gekennzeichnet sind. So bleibt die Testvariable trennscharf, die Replizierbarkeit gewährleistet und die Compliance in allen Phasen nachvollziehbar (Pineau et al., 2021, S. 8-12; Kohavi et al., 2007, S. 965-967).

Hinweis: Die Umsetzung des A/B-Tests hat ergeben, dass Adobe Firefly sich nicht für die Erstellung der Creatives eignet. Da im Vorgehen ChatGPT-5 bereits beschrieben wurde, ersetzt dieses Adobe Firefly. Weitere Informationen sind im Kap. 4.2 festgehalten und im Anhang 1 sowie 6 bis 15 protokolliert.

4.1.3 Aufbau eines Testplans

Ziel dieses Testplans ist die saubere Gegenüberstellung KI-gestützter und herkömmlicher Werbeanzeigen im Meta-Werbeanzeigenmanager unter Bedingungen, die kausale Effekte identifizierbar machen. Ausgangspunkt ist ein schriftliches Protokoll mit Hypothese, unabhängigen Variablen und primären Endpunkten, die vor Testbeginn festgelegt werden. Dieses Vorgehen reduziert Flexibilitäts- und Auswertungsbias und erhöht die Replizierbarkeit (Kohavi et al., 2020, S. 7-9). Dabei umfasst der Test die planvolle Ableitung der Anwendungsfälle, die Operationalisierung der Variablen in Creatives und Zielgruppenparametern, die Wahl der Randomisierungseinheit und die Konstanthaltung störanfälliger Faktoren. Außerdem beinhaltet er die Laufzeit- und Budgetplanung als methodisches Prinzip sowie vordefinierte Qualitäts- und Compliance-Prüfpunkte.

Design und Variantenaufbau: Für jeden Test wird genau eine manipulierbare Größe variiert: Creative-Erstellung mit KI versus konventionelles Bilddesign bei identischem Kampagnenziel, um die Logik des A/B-Tests beizubehalten und auswerten zu können. Alle übrigen Einstellungen - Kampagnenziel, Platzierungen, Bidding-Strategie, Geodaten, Frequenzobergrenzen und

Ausspielzeitraum - werden konstant gehalten. Dafür ermöglicht der Meta-Werbeanzeigenmanager A/B-Tests mit zufälliger Zuweisung auf Variantenebene, wodurch Optimierungsverzerrungen in den Testzellen minimiert werden (Orazi & Johnston, 2020, S. 189-193).

Randomisierung und **Einheit der Zuweisung:** Die Randomisierung erfolgt nutzerzentriert auf Anzeigensatz- oder Anzeigenebene mit gleicher Ausspielwahrscheinlichkeit. Hierbei ist die Wahl der Randomisierungseinheit zentral, weil sie die Messbarkeit und das Nutzererlebnis beeinflusst. In Plattformumgebungen sind Nutzer- oder Cookie-Level gängig, während Seiten- oder Kampagnen-Level nur in Sonderfällen geeignet sind (Kohavi et al., 2020, S. 25-28). Um die Varianz zu senken und die Präzision zu erhöhen, können vorab Demographien (etwa Land, Gerätetyp) geschichtet und innerhalb der Schichten randomisiert werden. Die methodische Logik folgt dem Prinzip, Varianz bereits während der Entwurfsphase durch Modellierung anzugehen (Kohavi et al., 2020, S. 34-36).

Störfaktorkontrolle: Drei Bias-Quellen sind in Social-Media-Experimenten besonders relevant: Aktivitätsbias, Targeting-Optimierung und Konkurrenzdruck im Auktionssystem. Diese führen bei Holdout-Designs ohne Anzeigenexposition in der Kontrolle häufig zu Über- oder Unterschätzungen der Kampagnenwirkung. Jene Risiken werden adressiert von einfachen A/B-Tests mit paralleler Anzeigenexposition in allen Zellen und identischen Targeting-Parametern (Gordon et al., 2019, S. 203-206; Orazi & Johnston, 2020, S. 191-195). Während der Laufzeit sind Änderungen an Zielgruppen, Budgets oder Creatives zu vermeiden, da sie die Randomisierung unterlaufen und die Auswertung entwerten (Kohavi et al., 2020, S. 12-13).

Laufzeit- und Budgetprinzipien: Die Planung orientiert sich an statistischer Teststärke und minimal nachweisbarem Effekt, nicht an operativen Budget-Zielgrößen. Feldexperimente in der Werbung benötigen aufgrund hoher Ergebnisvarianz häufig umfangreiche Stichproben (Lewis & Rao, 2015, S. 1942-1945). Praktisch sind demnach folgende Punkte sicherzustellen: ausreichende Laufzeit zur Erreichung der geplanten Stichprobengröße von min. 100 000 Kontakten, gleichmäßige Budgetallokation über die Testzellen und ein fixes Beobachtungsfenster ohne Alternative (Kohavi et al., 2020, S. 15-18).

Durchführung im Meta-Werbeanzeigenmanager: Die Experimentfunktion (A/B-Test) des Meta-Werbeanzeigenmanagers wird genutzt, um zwei Varianten als getrennte Zellen mit zufälliger Zuteilung anzulegen. Pro Zelle werden identische Kampagnenziele, Platzierungen und Gebotslogiken gesetzt. Creatives werden nach einem vorab definierten Creative-Protokoll versioniert, das Text, Bild/Video, Prompt-Parameter bei KI-Erstellung und Freigabestatus umfasst. Vor dem Start erfolgt eine technische Prüfung bezogen auf: Pixel- und Conversions-

Signale, Frequency Capping, Ausschlüsse, Brand-Safety-Listen und Reporting-Dimensionen. Während des Laufs werden nur vordefinierte Kontrollchecks durchgeführt (Orazi & Johnston, 2020, S. 192-197; Kohavi et al., 2020, S. 20-22).

Dokumentation und Replizierbarkeit: Alle Designentscheidungen, Randomisierungs-Seeds, Creative-Versionen, Targeting-Einstellungen, Budget-Zuweisungen und Abbruchkriterien werden in einem Studienprotokoll mit Zeitstempeln festgehalten. Hierbei erfolgt die Auswertung gemäß Vorab-Plan. Dieser strukturierte Testplan stellt sicher, dass Befunde reproduzierbar, auditierbar und ethisch vertretbar sind, ohne operative Anpassungen mit der Identifikation kausaler Effekte zu vermengen (Kohavi et al., 2020, S. 7-9; Gordon et al., 2019, S. 203-206).

4.1.4 Definition relevanter KPIs

Eine Awareness-Kampagne im Meta-Werbeanzeigenmanager hat das Ziel, eine umfassende Anzahl von Personen mit einer spezifischen Botschaft zu erreichen und eine positive Markenwahrnehmung zu schaffen. So werden bei A/B-Tests zwei Anzeigenvarianten in derselben Kampagne an zufällig ausgewählte Nutzergruppen ausgespielt. In der Literatur zu Online-Experimenten wird betont, dass sowohl die Hypothese als auch die zugehörigen Messgrößen vor dem Test festgelegt werden müssen. Nur so lässt sich der Einfluss des Stimulus isolieren, und opportunistische Interpretationen können vermieden werden (Kohavi et al., 2007, S. 2-3; Deng & Shi, 2016, S. 1-2). Umsatz- oder Conversionziele werden indes für Awareness-Fragestellungen nicht definiert. Stattdessen stützen sich die Analysen ausschließlich auf die sieben folgenden Kontakt- und Interaktionsmetriken: Reichweite, Impressionen, ausgegebener Betrag, CPM, Frequency, Unique-Reach-pro-Euro (OEC) und Interaktionen.

$$OEC = \frac{Reichweite}{Ausgegebener\ Betrag}\quad CPM = \frac{Ausgegebener\ Betrag}{Impressionen}\ x\ 1000$$

$$Frequency = \frac{Impressionen}{Reichweite}$$

Primär wird die Kosteneffizienz über die mittlere Differenz von CPM zwischen Variante A (KI-Creative) und Variante B (konventionelle Creative) geprüft. Sekundär werden Unique Reach pro Euro sowie Frequency berichtet (Kohavi et al., 2020, S. 3-7, 23-24).

Der ausgegebene Betrag und der CPM geben Aufschluss über die Budgeteffizienz, während Reichweite, Impressionen, OEC und Frequency das Ausmaß der Sichtbarkeit beschreiben. Interaktionen wiederum dienen zur qualitativen Einordnung des Engagements, ohne das Hauptziel zu ersetzen (Farris et al., 2006, S. 265, 268, 270-276, 295-296).

Entlang der Reichweite wird die Anzahl jener Personen gemessen, die eine Anzeige mindestens einmal gesehen haben. Sie wird auf Nutzerebene aggregiert, sodass jede Person nur einmal gezählt wird. Impressionen bezeichnen wiederum die Gesamtzahl der Auslieferungen. Dabei wird jede Anzeigeausspielung gezählt, auch wenn sie denselben Nutzer mehrmals erreicht. Die Frequency ergibt sich dann als Quotient aus Impressionen und Reichweite und gibt an, wie oft eine einzelne Person im Durchschnitt mit dem Werbemittel in Kontakt kommt. Diesbezüglich kann ein zu hohes Frequenzniveau zu Ermüdung führen, während ein zu niedriges mitunter die Erinnerungsleistung schwächt. Der ausgegebene Betrag umfasst die gesamten Werbekosten während des Messfensters. Der CPM (Cost per Mille) setzt diese Kosten in Relation zu tausend Impressionen und erlaubt den Vergleich der Effizienz beider Varianten. Interaktionen umfassen dabei sichtbare Nutzerhandlungen wie Likes, Kommentare oder Shares. In Awareness-Kampagnen spiegeln sie die Resonanz der Zielgruppe wider, sind jedoch kein primäres Erfolgsmaß (Farris et al., 2006, S. 274-276; Kronrod & Huber, 2019, S. 306-308; de Vries et al., 2012, S. 83-85). Schließlich quantifiziert die OEC, wie viele einzigartige Personen pro eingesetztem Euro erreicht werden (Kohavi et al., 2020, S. 6-7).

Die Mess- und Auswertungslogik erfordert, dass alle KPIs im gleichen Zeitraum und auf konsistenter Ebene erfasst werden. Die Nutzerzuweisung zu Variante A oder B erfolgt über einen Algorithmus per Zufall. So wird in der Literatur betont, dass Randomisierung nur dann kausal interpretiert werden kann, wenn jeder Nutzer die gleiche Chance erhält und die Zuordnung über die Testdauer persistiert (Kohavi et al., 2020, S. 7-8).

Zur Interpretation werden die KPIs der beiden Varianten verglichen. Dabei weist eine höhere Reichweite bei gleichem Budget auf eine vorzüglichere Eignung für Awareness hin. Wenn die Variante mit der größeren Reichweite zugleich eine geringere Frequency und OEC zeigt, erreicht sie entsprechend mehr Personen bei weniger Wiederholungen bzw. höherem Budgeteinsatz. Umgekehrt kann eine höhere Frequency bei stabiler Reichweite positiv sein, wenn die Botschaft mehrfach erinnert werden soll, birgt dann aber das Risiko der Überbelastung. Des Weiteren liefern CPM und der ausgegebene Betrag zusätzliche Effizienzindikatoren: Erhöht sich der CPM stark, kann dies auf ineffiziente Auktionsergebnisse oder steigenden Wettbewerb hindeuten (Farris et al., 2009, S. 288-295, 299-301; Yuan et al., 2013, S. 1). Interaktionen geben Auskunft über die qualitative Resonanz. So kann eine Variante, die eine beträchtliche Reichweite erzielt, jedoch nur geringe Interaktionen hervorruft, zwar zahlreiche Personen erreicht, das Engagement aber kaum gefördert haben. Solche Trade-Offs sind im Rahmen von Awareness zu bewerten, wobei Interaktionen als ergänzende, nicht als entscheidende Größe fungieren.

Typische Fallstricke sind eine ungewollt hohe Frequency, die zu Ermüdung führt, oder ein ansteigender CPM und sinkender OEC, der Budgetüberziehung verursacht. Ferner kann eine Diskrepanz zwischen Reichweite und Interaktionen darauf hinweisen, dass die Botschaft zwar verbreitet, aber nicht als relevant wahrgenommen wird (de Vries et al., 2012, S. 86-88; Peters et al., 2013, S. 285-286, 292-293; Kronrod & Huber, 2019, S. 306-314; Yuan et al. 2013, S. 3-4).

4.2 Praktische Anwendung und prototypische Umsetzung

4.2.1 Einrichtung einer Testkampagne

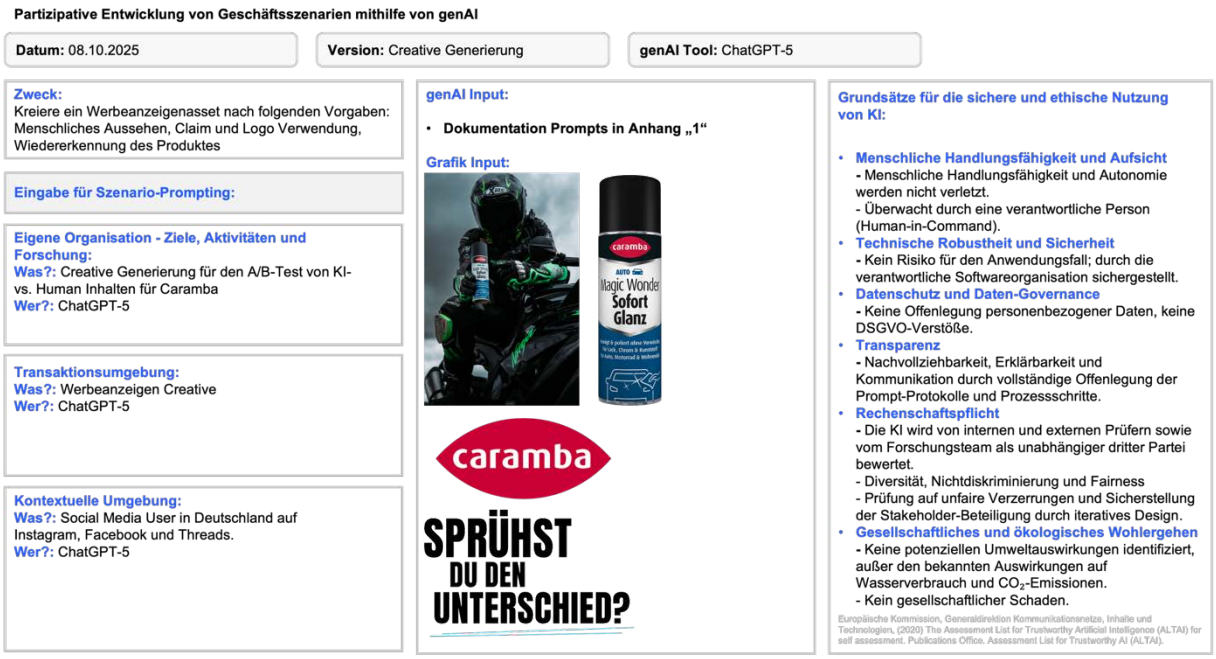

Abbildung 3: Partizipative Entwicklung von Geschäftsszenarien mithilfe von genAI zur Entwicklung von Creatives für das A/B-Testing, Quelle: Eigene Darstellung in Anlehnung an Roth et al. (2024, S. 530).

Die Testkampagne wurde als kontrolliertes Set-up angelegt, um die Wirkung KI-unterstützt produzierter Werbemittel gegenüber manuell erstellten Pendants vergleichbar zu machen. Grundlage bildete hier ein zweistufiger Kreativ-Workflow mit getrennten Streams für Bild und Text sowie einer finalen Produktionsschicht zur Formatangleichung. Auf dieser Basis wurden zwei inhaltlich konsistente Asset-Bündel mit ID-Kennzeichnung generiert (Manuell ID: 2025-1, KI: 2025-2, mit KI-Hinweis: 2025-2b), die in der Kampagnenstruktur des Meta-Werbeanzeigenmanagers als eigenständige Testarme geführt werden. Für das visuelle Material des KI-Arms kamen generative Bildmodelle zum Einsatz, wobei die Bildproduktion mit einem Text-zu-Bild-Verfahren von ChatGPT-5 erfolgte. Hierbei erwies sich die Erstellung mit Adobe Firefly

als ungenügend, da keine CI-konforme Umsetzung möglich war. Motivisch wurde ein konsistentes Set aus Produktdarstellung und Anwendungskontext gewählt. Zur Sicherstellung der Übertragbarkeit wurden alternative deckungsgleiche Prompts systemübergreifend eingesetzt und bei Bedarf adaptiert.

Das manuelle Creative wurde gebildet aus vorhandenen Markenassets, bestehend aus Markenkennzeichen „Caramba“; Shootingmaterial, sowie einem prägnanten, produktbezogenen Claim „Sprühst du schon?“. So war gewährleistet, dass die Vergleichsbedingungen zwischen KI- und Human-Visuals hinsichtlich Format, Markierung und Motivstruktur konstant blieben.

Die Textkomponente wurde auch in zwei Strängen implementiert. Für den KI-Arm generierte ChatGPT-5 auf Grundlage der Produktpositionierung fünf Varianten-Triple aus Überschrift, Primärtext und Kurzbeschreibung. Inhaltlich wiederkehrende Leitmotive waren die schnelle, rückstandsarme Reinigung ohne Vorwäsche und die Eignung für Lack, Chrom und glatte Kunststoffe. Zudem wurde auf den Einsatz nach der Tour im Motorrad- und Auto-Kontext sowie auf ein wachsbasierendes, langanhaltendes Schutzfinish hingewiesen. Tonal adressierten die Varianten eine junge, mobil affine Zielgruppe und kombinierten Nutzenargumente mit knappen, dynamischen Aufforderungen. Der Human-Arm umfasste manuell verfasste Pendants mit identischer Informationsarchitektur. Zur internen Nachverfolgbarkeit wurden beide Textsets den Visual-Paketen zugeordnet, sodass jeweils in sich stimmige Anzeigenvarianten entstanden.

Sämtliche Visuals wurden im 4:5-Format finalisiert, mit einheitlichem Markenauftritt versehen und qualitätsgesichert. Dabei wurden die Textbausteine hinsichtlich Länge, Zeilenumbruch und Plattformkonventionen ausbalanciert, ohne die semantischen Kerne zu verändern. Anschließend wurden folgende, klar definierte Anzeigenausprägungen aus den Bausteinen gebildet: „KI-Visual plus KI-Textbausteine“ und „Human-Visual plus Human-Textbausteine“. Mischformen wurden im Rahmen dieser Einrichtung bewusst ausgeschlossen, um die Zuordnungseffekte eindeutig zu halten.

Die Anbindung an den Meta-Werbeanzeigenmanager erfolgte entlang einer schlanken Kampagnenarchitektur, die auf Vergleichbarkeit und Replikationsfähigkeit ausgerichtet war. In der Kampagnenebene wurde einheitlich ein Testziel hinterlegt, das auf die Gegenüberstellung beider Kreativarme abzielte. Auf Anzeigengruppen-Ebene wurden die zwei Asset-Bündel als getrennte Testarme gespiegelt, sodass Differenzen der Leistungskennzahlen eindeutig auf die kreative Herkunft zurückgeführt werden können. Innerhalb der Anzeigenebene wurden die fi-

nalisierten Kombinationen aus Visual und Text jeweils als einzelne Anzeigenvarianten angelegt. Dabei wurde die ID-Logik der Visual-Pakete übernommen, um Aussteuerung und Reporting technisch rückführbar zu halten. Dieser Prozess wurde für den A/B-Test Phase 2 adaptiert.

4.2.2 Automatisierte Generierung von Anzeigentexten

Die Anzeigentexte wurden automatisiert mit ChatGPT-5 erstellt und in einer dreigliedrigen Struktur aus Überschrift, Primärtext und Kurzbeschreibung ausgegeben. Der Prozess zielte darauf, mehrere inhaltlich konsistente Varianten zu erhalten, die das Produktversprechen knapp, verständlich und wiedererkennbar formulieren. Grundlage bildete die im Kreativteil verankerte Anwendungslogik: schnelle Oberflächenpflege ohne aufwendige Vorbereitung, sichtbarer Glanz nach kurzer Behandlung sowie der Einsatz im Kontext motorisierter Freizeitmobilität. Das Modell erzeugte in einem Durchlauf mehrere Überschriften mit klaren Aufforderungs- und Nutzenmustern, die Primärtexte konkretisierten die Anwendung in wenigen Schritten, und die Beschreibungen verdichteten den zentralen Vorteil in eine prägnante Abschlussformulierung. Die Ausgaben wurden in der erzeugten Dreiteilung beibehalten und unverändert den jeweiligen Anzeigenvarianten zugeordnet.

Inhaltlich folgten die generierten Texte wiederkehrenden Leistungsmotiven.

1. **Der geringe Aufwand stand im Vordergrund:** Die Pflege erfolgt zügig, ohne gesonderte Vorwäsche oder umfangreiche Hilfsmittel, was den unmittelbaren Einsatz nach einer Fahrt erleichtert.
2. **Der Glanzeffekt wurde als wahrnehmbares Endergebnis hervorgehoben,** der mit einer versiegelnden Komponente verknüpft ist und damit über die reine Säuberung hinausreicht.
3. **Adressierung der breiten Materialverträglichkeit**, explizit für Lack, Chrom und glatte Kunststoffe, wodurch unterschiedliche Einsatzbereiche abgedeckt werden.

Diese drei Motive wurden konsequent in den drei Textebenen variiert: Überschriften in Form kurzer Imperativ- oder Dreiklangstrukturen, Primärtexte mit kompakten Anwendungshinweisen und Beschreibungen als kondensierter Nutzenabschluss.

Die Tonalität der generierten Texte war dynamisch und auf knappe Lesbarkeit in Umgebungen mit hoher Scrollgeschwindigkeit ausgerichtet. Stilistisch zeigten die Überschriften rhythmische Muster mit reduzierten Satzfragmenten. In den Primärtexten wurden kurze Hauptsätze und eingefügte Nutzenanker verwendet, um die Abfolge von Anwendung, Ergebnis und Vorteil klar darzustellen. Entsprechend funktionierten die Beschreibungen als verdichteter Slogan, der

den Kernnutzen in wenigen Wörtern fixiert. Einzelne Ausgaben betteten optionale Markierungen ein, etwa kurze Schlagworte oder einen Marken-Hashtag zur Wiedererkennung. Diese blieben integraler Bestandteil der KI-Ausgabe, wurden jedoch in der weiteren Zusammenstellung nur dort verwendet, wo sie in das jeweilige Anzeigenlayout passen.

Für die spätere Verwendung im Anzeigen-Set-up wurden die von der KI erzeugten Variante-Triple ohne Mischung der Ebenen weiterverarbeitet. Jede Überschrift blieb dabei jeweils mit dem zugehörigen Primärtext und der passenden Kurzbeschreibung verknüpft, um die Sinnhaftigkeit der Aussage beizubehalten. Auf diese Weise entstanden mehrere vollständige Textpakete, die direkt einer jeweiligen visuellen Ausprägung zugeordnet werden konnten. Mischformen zwischen Überschriften, Primärtexten und Beschreibungen verschiedener KI-Varianten wurden in dieser Phase nicht gebildet, um Eingriffe in die vom Modell erzeugte Binnenlogik zu vermeiden und die anschließende Beurteilung der Textleistung eindeutig auf Variantenebene zu halten.

4.2.3 Zielgruppensegmentierung und Gebotsoptimierung

Die Zielgruppenansprache wurde auf Basis der in den Kreativ- und Text-Streams angelegten Nutzungsszenarien operationalisiert. Ausgangspunkt waren die in der KI-Bild- und KI-Textgenerierung konsistent wiederkehrenden Anwendungskontexte sowie die dort verankerten Produktnutzen. Hierbei verbanden die generativen Bildmotive eine prägnante Produktdarstellung mit einer dynamischen Nutzungsszene im Motorradumfeld und waren in einem einheitlichen 4:5-Format mit gedeckten Farben und gedämpfter Lichtführung ausgearbeitet. Dazu traten von der KI erstellte Textpakete aus Überschrift, Primärtext und Kurzbeschreibung, die die schnelle Pflege ohne Vorwäsche, den sichtbaren Glanzeffekt und die Materialverträglichkeit für Lack, Chrom und glatte Kunststoffe betonen. Diese inhaltlichen Konstanten bildeten die semantischen Koordinaten für die Segmentierung. Entsprechend adressierten die jeweiligen Varianten dann situative Momente wie den kurzen Stopp nach der Tour, die schnelle Wiederherstellung des Glanzes oder den übertragenen Einsatz über Fahrzeugkategorien hinweg.

Die KI-gestützte Segmentierung zeigte sich damit als systematische Varianz in Motivkern und Nutzengewichtung bei konstanter Informationsarchitektur. Durch die Parallelität mehrerer inhaltlich präziser, aber voneinander abgrenzbarer Varianten wurde eine feinere Ausrichtung der Ansprache vorbereitet, ohne zusätzliche Metadaten oder externe Merkmale zu benötigen. Entscheidend war die Stabilisierung der Kernaussagen über alle Ausprägungen hinweg, damit Unterschiede in der Rezeption auf die inhaltliche Schwerpunktsetzung zurückgeführt werden

konnten. So trug die formale Vereinheitlichung der Ausspielungsformate dazu bei, dass die Segmentierung über Inhalte und nicht über Darstellungsartefakte realisiert wird.

Im Kontext der Gebotslogik wurde die Vergleichbarkeit der kreativen Herkünfte in der Kampagnenarchitektur priorisiert. Die Einrichtung spiegelte die Asset-Bündel als getrennte Testarme, die jeweils aus vollständig verknüpften KI-Text-/Visual-Kombinationen bzw. ihren manuellen Pendants bestanden. Damit war die Grundlage geschaffen, Leistungsunterschiede den kreativen Quellen zuzuschreiben. Innerhalb dieser Struktur stand die Gebotsoptimierung im Dienst der sauberen Gegenüberstellung. Die Anzeigen wurden so vorbereitet, dass die kreative Herkunft als alleinige Differenzierungsvariable fungierte und keine Mischformen entstanden, die die Aussteuerung in Richtung einzelner Varianten hätte verzerren können. Prozessseitig wurde die Qualitätssicherung der Assets vorgezogen, sodass die spätere Ausspielung nicht durch formale Inkonsistenzen beeinflusst wurde.

Für das Monitoring bedeutete die KI-gestützte Segmentierung, dass die Auswertung entlang der inhaltlichen Profile erfolgen konnte. Da jede Ausprägung über eine eindeutig definierte Ansprachelinie verfügte, konnten Beobachtungen zur Rezeption den entsprechenden Szenarien zugeordnet werden. Die vorbereitete Kampagnenstruktur im Meta-Werbeanzeigenmanager unterstützte diese Zuordnung, indem sie die Asset-Bündel technisch trennscharf hielt und die Varianten mit internen Kennzeichnungen versah. Dadurch wurde die spätere Betrachtung von Leistungskennzahlen innerhalb der Segmente möglich, ohne dass die Anlage selbst zusätzliche Segmentparameter erforderte. Dabei blieb die Gebotslogik kompatibel zur Segmentstruktur, weil sie keine Vermischung der kreativen Ebenen einführte und die Anzeigenausspielung entlang der vorbereiteten Varianten erfolgen konnte.

4.3 Evaluation der KI-gestützten Kampagnenleistung

4.3.1 Systematische Erhebung und Auswertung der Kampagnendaten

	Ausgegebener Betrag (€)	Frequenz	Reichweite	CPM (€)	OEC	Interaktionen
Test_Kampagne_ Bekanntheit_KI (Phase 1)	244,95	1,03	163322	1,45	667,02	172
Test_Kampagne_ Bekanntheit_Human (Phase 1)	244,85	1,00	163417	1,50	667,14	166
Test_Kampagne _Bekanntheit_ KI_Hinweis (Phase 2)	244,98	1,01	158412	1,53	646,63	166
Test_Kampagne_ Bekanntheit_Human (Phase 2)	244,76	1,01	144866	1,69	591,87	177

Tabelle 2: Ergebnisse der A/B-Tests, Quelle: Eigene Darstellung. Weiterführende Informationen im Anhang 36.

Zur Evaluation kamen zwei A/B-Tests zur Anwendung, die vom Meta-Ads-Manager zur Verfügung gestellt wurden. Beide Experimente liefen in zwei Phasen als Awareness-Kampagne für die Marke Caramba in Deutschland (Ziel „Reichweite“).

- Phase 1: 11.10-18.10.2025
- Phase 2: 18.10-25.10.2025

Im A/B-Test Phase 1 wurden KI-generierte und manuell erstellte Werbemittel ohne Hinweis auf KI-generierte Inhalte gegeneinander getestet. Daraufhin wurde derselbe Vergleich im A/B-Test Phase 2 um den expliziten Hinweis „Mit KI generiert.“ ergänzt. Jeder Arm erhielt ein

Budget in Höhe von 250 EUR und wurde über einen Zeitraum von sieben Tagen verteilt. Die Zuweisung der Nutzer erfolgte per Zufall, wobei die „Human"-Variante in sich durch Angaben von Demografie (z. B. Motorradreise und -sport) begrenzt wurde. Hierdurch erhielten beide Varianten identische Rahmenbedingungen mit nicht überlappenden Zielgruppen.

Die Exporte aus dem Meta-Ads-Manager enthielten pro Anzeigengruppe Felder wie Berichtsstart, Berichtsende, Campaign/Ad-IDs, Reach (einzigartige Personen), Impressions, Spend, Frequency und CPM (Kosten pro 1000 Impressionen). Da die Messfenster bereits den Zeitraum der Lernphase umfassten, wurden alle Zeilen mit learning_phase_flag = TRUE entfernt; damit flossen nur stabile Leistungsdaten in die Analyse ein. Die Spalten Reach, Impressions und Spend wurden als numerische Variablen importiert.

Die Hauptkennzahl zur Bewertung der Kampagnenleistung ist der CPM (Cost per Mille). Sekundär dienen OEC (Unique Reach per Euro) und Frequency als KPIs (Kohavi et al., 2020, S. 6-7):

Die Daten zeigen (Tabelle 2), dass im ersten Test beide Varianten nahezu identische Reichweiten (≈ 163 000 Reichweite) bzw. ausgegebene Beträge erzielten. Die KI-Variante erzeugte jedoch mehr Impressionen (168 938) als die manuelle (163 785), wodurch der CPM mit 1,45 EUR leicht günstiger ausfiel als bei der manuellen Version (1,50 EUR). Der jeweilige OEC war in diesem Test mit **667,03** beziehungsweise **667,14** Personen pro Euro praktisch identisch, was darauf hinweist, dass die Effizienz hinsichtlich der Reichweite pro Budget bei beiden Varianten gleich ist. Im zweiten Test zeigten die Varianten indes erhebliche Unterschiede. Hier erreichte die manuelle Creative 144 866 Personen, während die KI-Variante mit Kennzeichnung 158 412 Personen anvisierte. Trotz nahezu identischem Budget reduzierte sich der CPM von 1,66 EUR (manuell) auf 1,53 EUR (KI mit Hinweis). Noch bedeutender ist der OEC-Sprung von **591,86** auf **646,32** Personen pro Euro, was einer deutlichen Effizienzsteigerung entspricht.

Diese KPIs bilden die Grundlage für die Bewertung der Kampagnenleistung in den folgenden Abschnitten. Die vollständige Aufschlüsselung der Daten und weitere Metriken (z. B. Beitragsinteraktionen) sind im Anhang 36 dokumentiert.

4.3.2 Vergleichende Analyse: KI-basiert vs. manuell gesteuert

Die Kampagnen wurden in zwei siebentägigen Phasen parallel ausgeliefert, wodurch sichergestellt werden konnte, dass Schwankungen beide Varianten gleichermaßen betreffen. Die Analyse fokussiert sich im Folgenden auf den primären Endpunkt *CPM* (Cost per Mille), ergänzt durch die KPIs *OEC* (Unique Reach pro Euro) und *Frequency*. Die Kennzahlen wurden

in Kapitel 4.1.4 definiert. Tabelle 2 zeigt die absoluten und relativen Unterschiede des CPM zwischen den KI-basierten Werbemitteln und den manuell erstellten Varianten.

In A/B-Test 1 (ohne Kennzeichnung) lagen die CPM-Werte sehr nahe beieinander. So erzielte die KI-Variante einen CPM von 1,45 EUR bzw. die manuelle Variante 1,50 EUR. Daraus ergibt sich ein absoluter Unterschied von −0,046 EUR (relativer Uplift: −3,1 %). Im zweiten Experiment (mit dem Hinweis „Mit KI generiert.“) zeigten sich deutliche Unterschiede. Hier erreichte die KI-Variante mit Kennzeichnung einen CPM von 1,53 EUR, während die manuelle Creative 1,66 EUR benötigte. Der absolute Unterschied beträgt −0,137 EUR und entspricht einem relativen Uplift von −8,2 %. Somit lässt sich eine Kostenreduktion pro 1000 Impressionen feststellen. Angesichts des identischen Budgets und der nicht überlappenden Zielgruppen spricht dieses Ergebnis für eine Effizienzsteigerung durch KI-generierte Creatives mit Kennzeichnung.

Neben dem primären KPIs wurden die OEC-Werte (Unique Reach pro Euro) und die durchschnittliche Kontaktfrequenz als KPIs analysiert. In A/B-Test 1 zeigte sich kein relevanter Unterschied in der Effizienz der Reichweitenverteilung: Beide Varianten erzielten knapp 667 Personen pro ausgegebenem Euro. Dabei entspricht der absolute OEC von −0,12 Personen pro Euro einer vernachlässigbaren relativen Differenz von −0,02 %. Die leicht höhere Frequency der KI-Variante (1,034 vs. 1,002) deutet zwar darauf hin, dass pro Person geringfügig mehr Impressionen ausgespielt wurden, der Uplift von +3,2 % bleibt jedoch innerhalb des akzeptablen Rahmens.

Deutlich anders verhielt sich dies bei A/B-Test 2. Hier erreichte die KI-Variante mit Kennzeichnung 646,32 Personen pro Euro, die manuelle lediglich 591,86. Der absolute Uplift von +54,46 Personen pro Euro entspricht einer relativen Steigerung von +9,2 % und weist auf eine verbesserte Effizienz hin. Gleichzeitig lag die Kontaktfrequenz geringfügig niedriger (1,012 vs. 1,015), sodass die verbesserte Reichweite nicht auf eine aggressive Ausspielung zurückzuführen ist. Somit bestätigen die Ergebnisse, dass KI-generierte Creatives mit Offenlegung nicht nur die Kosten pro Impression senken, sondern auch mehr einzigartige Personen pro Budgeteinheit erreichen.

Die vergleichende Analyse führt demnach zu zwei zentralen Erkenntnissen. So deuten die nahezu identischen OEC-Werte und der nicht signifikante CPM-Unterschied im ersten Test darauf hin, dass KI-Creatives ohne Kennzeichnung die Effektivität der Awareness-Kampagne nicht systematisch erhöhen. Die höheren Impressionen resultieren dabei lediglich aus einer leicht höheren Frequenz, sodass die Kosten pro 1000 Impressionen sinken, ohne die Reich-

weite pro Euro zu verbessern. Das Hinzufügen eines Hinweises auf den KI-Ursprung verbessert dann die Performance: Sowohl der CPM als auch der OEC zeigen klare Uplifts, während die Frequenz stabil bleibt. In der vorliegenden Kampagne verschlechterte die Kennzeichnung die Performance demnach nicht, sondern verstärkte möglicherweise die Wahrnehmung von Innovation oder Kreativität. Mögliche Erklärungen reichen von der Thematik (Automobilzubehör) über die Verwendung generischer Visuals bis zu einer geringeren Skepsis der Zielgruppe gegenüber KI-Medien.

Zusammenfassend liefern die Daten ein gemischtes Ergebnis: Ohne Kennzeichnung ist der Vorteil von KI-basierten Creatives minimal, während mit Kennzeichnung signifikante Effizienzgewinne erzielt werden. Entsprechend unterstreichen die Ergebnisse, dass Entscheidungen über den Einsatz generativer KI im Social-Media-Advertising sorgfältig experimentell validiert werden müssen.

4.3.3 Reflexion der Hypothese

Die eingangs formulierte Hypothese lautete, dass generativ mit KI erstellte Werbeanzeigen unter identischen Targeting-, Platzierungs- und Budgetbedingungen im Meta-Werbeanzeigenmanager eine höhere Reichweite pro Budgeteinheit erzielen. Dies sollte sich - im Vergleich zu konventionell von Menschen gestalteten Creatives - in niedrigeren Kosten pro tausend Impressionen (CPM) ausdrücken. Die beiden durchgeführten A/B-Tests liefern diesbezüglich ein gemischtes Bild. Im ersten Experiment ohne Kennzeichnung der KI-Herkunft lagen CPM und OEC der KI-Variante nur marginal unter bzw. gleichauf mit der manuellen Vergleichsgruppe (relativer Uplift −3,1 % und −0,02 %). Diese Unterschiede waren nicht signifikant und wurden von einer leicht höheren Kontaktfrequenz begleitet. Somit widersprechen die Daten der Hypothese für einen kennzeichnungslosen Einsatz von KI-Creatives. Anders verhielt sich das zweite Experiment mit dem Hinweis „Mit KI generiert“: Hier sank der CPM der KI-Variante um rund 8,2 %, und der OEC stieg um etwa 9,2 % gegenüber der manuellen Aussteuerung. Insgesamt unterstützt die zweite Phase die Hypothese, während die erste sie nicht bestätigt. Für Caramba gilt daher: Ein generischer Vorsprung der KI ist nicht gegeben, doch unter transparenter Kennzeichnung können Effizienzvorteile entstehen.

Insgesamt zeigt die Reflexion, dass KI-gestützte Werbemittel Potenzial haben, doch ihre Wirksamkeit weder garantiert noch universell ist. Vielmehr muss diese anhand sauberer Experimente kontextualisiert und laufend validiert werden.

5 Zukunftsperspektiven und Handlungsempfehlungen

5.1 Szenarien für die Integration von KI im Social-Media-Management

Ausgehend vom Instagram-Audit (Kap. 3.3.2) bzw. von den im Theorieteil beschriebenen Rollen von KI als Ermöglicher datengetriebener Routinen (Kap. 2-3) sowie den A/B-Tests im Meta-Werbeanzeigenmanager (Kap. 4) lassen sich für Caramba drei aufeinander aufbauende Integrationspfade beschreiben; diese schließen an die aktuelle Organisationslage nach dem MBO, an die duale B2C/B2B-Ausrichtung und an die identifizierten Lücken bei Soll-KPIs, Attribution, Commerce-Nutzung und Governance an. Die Szenarien verbinden die Logik dynamischer Fähigkeiten mit plattformspezifischen Funktionen von Instagram und berücksichtigen die Balance zwischen Automatisierung, Authentizität und menschlicher Qualitätskontrolle.

Im Basisszenario „Messbare Assistenz“ steht die Stabilisierung von Zielen, Daten und Prozessen im Vordergrund. Die im Audit festgestellte Ziel-Mess-Lücke sollte geschlossen werden, indem Oberziele in wenige formatbezogene Soll-KPIs für Reichweite und Interaktionsqualität übersetzt und als verbindlicher Steuerungsrahmen dokumentiert werden. Parallel sollte die fehlende Attributionskette geschlossen werden: UTM-Konventionen und Conversion-Signale werden demnach standardisiert, Commerce-Funktionen auf Instagram aktiviert und mit klaren CTA verknüpft, sodass Reichweiten- und Interaktionsleistungen über den Plattformrand anschlussfähig werden. Reels und Feed erhalten wiederum klar definierte Rollen entlang ihrer beobachteten Wirklogiken: Reels als Treiber der Skalierung und der Feed als Anker für konsistentes Engagement. Hier kommt KI als Prognose- und Monitoring-Layer zum Einsatz (z. B. Themenpriorisierung), während die Veröffentlichung nach einem verschriftlichten Freigabeprozess mit „Human-in-the-Loop“ erfolgt. Im Werbeanzeigenmanagement wird Advantage-basierte Automatisierung vorsichtig und nachvollziehbar genutzt. Kreative Assets bleiben indes statisch versioniert und werden vor Ausspielung redaktionell geprüft. Dieses Fundament reduziert Abhängigkeiten von Einzelwissen, erhöht die Reproduzierbarkeit und schafft die Voraussetzung für belastbare Experimentierroutinen.

Caramba modularisiert Inhalte entlang wiederkehrender Nutzenmotive und Zielgruppenkontexte und setzt generative Verfahren gezielt in der Ideation und Kanaladaption ein. Die finale Tonalität bleibt jedoch redaktionell kuratiert, um Authentizitätsrisiken zu begrenzen. Für Instagram wird ein szenariobasierter Redaktionsplan etabliert, der B2C-nahen Kurzvideos mit hohem Reichweitenpotenzial priorisiert und Feed-Formate für dialogische Vertiefung nutzt. Zeitfenster, Vividität und Interaktivität werden fortlaufend datenbasiert kalibriert. Im Meta-Werbe-

anzeigenmanager wird eine feste A/B-Test-Kadenz verankert, die creative Varianten, Platzierungsbündel und Zielgruppenansprachen getrennt prüft. Dabei dienen die A/B-Ergebnisse aus Phase 1 und 2 als organisationsinterne Evidenz für die Parametrisierung künftiger Tests. Der in Phase 2 beobachtete Effizienzgewinn bei expliziter Kennzeichnung „Mit KI generiert." wird als Hypothese in die Routine überführt: Wo generative Assets genutzt werden, erfolgt entsprechend eine transparente, plattformkonforme Kennzeichnung, und es wird systematisch geprüft, in welchen Use-Cases sie Effizienzgewinne stiften, ohne die Wahrnehmung der Traditionsmarke zu belasten. Daten- und Modell-Governance werden diesbezüglich parallel ausgebaut: Creative-Protokolle, Freigaberegeln und klare Verantwortlichkeiten sichern so die Nachvollziehbarkeit.

Führend sollten die ausgebauten Routinen zu einem geschlossenen, lernenden Steuerungssystem verknüpft werden, in dem KI kreative, analytische und mediale Teilprozesse koordiniert und menschliche Expertise kuratiert, priorisiert und legitimiert. Social Listening fungiert hier als Market-Sensing-Funktion, die Themen, Stimmungsumschwünge und Krisensignale in nahezu Echtzeit in die Content- und Kampagnenplanung rückkoppelt. Die redaktionelle Pipeline arbeitet indes mit variantenfähigen Kreativbausteinen, um kulturelle Passung und Glaubwürdigkeit zu sichern. Im Werbeanzeigenmanagement wird die Budget- und Variantensteuerung stärker datengetrieben innerhalb klarer KPIs organisiert. Automatisierte Vorschläge zur Umverteilung zwischen Creative-Armen oder Formaten werden akzeptiert, wenn sie die vereinbarten Soll-KPIs adressieren und eine dokumentierte Freigabe durchlaufen. Attribution und Commerce sind wiederum vollständig integriert, sodass Instagram-Leistungen mit nachgelagerten Verhaltenszielen verknüpft werden. Dadurch verschiebt sich die Steuerung von Plattform-Proxys hin zu belastbaren Wirkbeiträgen. Darüber hinaus wird die transparente Kennzeichnung synthetischer Anteile als Standard etabliert und mit einer Kommunikationslogik verknüpft, die die Rolle von KI als Werkzeug erklärt und damit Erwartungsklarheit schafft. Für eine Traditionsmarke wie Caramba entsteht so ein Modell, das die historische Problemlöser-Identität in beschleunigte, datenfundierte Routinen übersetzt: KI trägt hierbei die Skalierung und Entlastung, während die Marke die Grenzen setzt und Menschen die Passung, Qualität und Verantwortung sichern.

5.2 Potenziale und Chancen für Caramba

Aus den Ergebnissen resultieren für Caramba vier miteinander verschränkte Potenzialfelder, die die nach dem MBO erhöhte Handlungsfreiheit in ein belastbares, lernfähiges Modell übersetzen:

Erstens eröffnet **KI die Skalierung redaktioneller Wertschöpfung**, ohne den in der Markenidentität verankerten Authentizitätsanspruch preiszugeben. Generative Verfahren beschleunigen hierbei die Ideation, Variantenbildung und kanaladäquate Adaption bzw. erlauben es, die im Audit sichtbare Formatlogik systematisch zu nutzen, indem Reels als Reichweitenmotor kuratiert und Feed-Beiträge als Dialoganker mit konsistenter Tonalität eingesetzt werden. Diesbezüglich bleibt die im Theorieteil hervorgehobene Notwendigkeit einer menschlichen Qualitätsinstanz leitend: „Human-in-the-Loop" stellt somit die Passung und Kontextsensibilität sowie den Markenanschluss sicher. Für die Traditionsmarke ist dies eine doppelte Chance: KI trägt die Reichweite und Geschwindigkeit, während die redaktionelle Kuratierung die Glaubwürdigkeit wahrt.

Zweitens stärkt **KI die Market-Sensing-Fähigkeit** als dynamische Fähigkeit im Sinne der identifizierten Theorieperspektive. So verdichten KI-gestütztes Social Listening, Sentiment- und Themenmodellierung Signale aus Community-Interaktionen und öffentlichen Diskursen zu umsetzbaren Prioritäten für Content und Community-Management. Damit können sie im Voraus planen, sich an das Audit Moderation und Krisenfrüherkennung anschließen, Ressourcen zwischen B2C-nahen Servicefragen und B2B-spezifischen Anwendungsthemen steuern sowie Eskalationen entlang festgelegter Schwellenwerte auslösen. Für Carambas duale Ausrichtung bedeutet dies: Im Consumer-Kontext werden Nutzenmomente und Pflege-Routinen in kurzen, visuell prägnanten Sequenzen priorisiert, während im professionellen Kontext anwendungsnahe Demonstrationen und Sicherheits- bzw. Produkthinweise redaktionell verdichtet werden. Hier liefert KI die analytische Vorarbeit, und die redaktionelle Übersetzung bleibt bewusst menschlich.

Drittens ermöglicht **KI eine datenbasierte Automatisierung** der Kampagnenaussteuerung auf Instagram. Entsprechend können Meta-Advantage-Funktionen für Caramba zur Effizienzquelle werden, wenn Creatives klar versioniert, KPIs definiert und Experimente als Routine etabliert sind. Methodisch stärkt eine feste Test-Kadenz die Lernfähigkeit der Organisation und verankert die im Theorieteil (Kap. 2-3) geforderte kausale Validierung von Kreativ-Hypothesen.

In Verbindung mit der im Audit geforderten Rollenklärung der Formate kann Caramba so kreative Varianten, Platzierungsbündel und Zeitfenster strukturiert gegeneinander testen, ohne die Markenführung zu fragmentieren.

Viertens wird durch **KI ein Anschluss an wirkungsbasierte Steuerung** geschaffen, sofern die im Audit identifizierten Mess- und Governance-Lücken geschlossen werden. Dabei liegt der zentrale Hebel in der Herstellung einer belastbaren Ziel-Mittel-Kette: UTM-Konventionen, Conversion-Signale und die Aktivierung von Commerce-Funktionen schaffen diesbezüglich die Grundlage, um die in der Plattform erzielte Sichtbarkeit mit nachgelagerten Verhaltenszielen zu verknüpfen. Daraus wiederum können KI-gestützte Berichte verdichtete, zielgruppenspezifische Lerneffekte ableiten und den Redaktions- und Kampagnenplan im Sinne eines geschlossenen Feedback-Loops justieren. Für Caramba entsteht so die Möglichkeit, die bisher vorwiegend plattforminternen Proxys um kontextspezifische Wirkmaße zu ergänzen und Budgets entlang klarer Soll-Beiträge zu priorisieren. Auf dieser Basis wird Personalisierung zu einem anpassbaren Instrument: Durch Steigerung der Relevanz und Aufrechterhaltung der Transparenz können somit Risiken begrenzt werden, und die Effektivität sozialer Ausspielungen wird entsprechend verbessert.

5.3 Risiken und Herausforderungen der Umsetzung

Die Umsetzung KI-gestützter Routinen im Social-Media-Management von Caramba ist mit fünf miteinander verknüpften Risikofeldern verbunden.

Datenqualität und -integration sind der zentrale Engpass. Hierbei verhindern die im Audit identifizierten Lücken bei UTM-Konventionen, Conversion-Attribution und Commerce-Funktionen eine belastbare Ziel-Mittel-Kette und zwingen die Steuerung auf Plattform-Proxys. Ohne konsistente Datenmodelle, klare Qualitätsregeln und dokumentierte Schnittstellen drohen Prognosefehler, die Personalisierung und Variantentests verzerren. Überdies wird das Risiko hier organisatorisch verschärft: Eine Einzelverantwortung ohne definierte Workflows erhöht demnach die Anfälligkeit für inkonsistente Messpunkte, lückenhafte Versionierung und fehlende Eskalationslogiken. Für Caramba bedeutet dies, dass KI-basierte Empfehlungen nur so verlässlich sind wie die darunter liegenden Governance- und Datenprozesse.

Akzeptanz und Kompetenzaufbau stellen zudem eine nicht zu unterschätzende Hürde dar. Im Theorieteil (Kap. 2-3) wird darauf verwiesen, dass Automatisierung ohne „Human-in-the-Loop“ die Beziehungsqualität und das Vertrauen gefährden. Gleichzeitig zeigen Praxis- und Studienhinweise, dass fehlende Schulungen, unklare Rollen und diffuse Verantwortlichkeiten die Einführung hemmen und Widerstände verstärken. Besonders mittelständische Organisationen

benötigen strukturierte Lernpfade, um Daten-, Kreativ- und Compliance-Kompetenzen zu synchronisieren. Im Kontext eines Traditionsunternehmens mit dualer B2C/B2B-Ausrichtung verschärft sich entsprechend die Aufgabe. Teams sollen demnach souverän zwischen nutzernahem B2C-Storytelling und informationsstarker B2B-Kommunikation wechseln und KI-Ergebnisse gezielt aufbereiten.

Darüber hinaus entstehen Authentizitäts-, Fairness- und Transparenzrisiken entlang der Content- und Anzeigenkette. Im Theorieteil wird verdeutlicht, dass generative Systeme ohne redaktionelle Kontrolle Tonalität, kulturelle Passung und Zielgruppen-Nuancen verfehlen können. Zugleich sind Verzerrungen in Trainings- und Moderationsmodellen ausgewiesen - etwa bei negierten Hassäußerungen oder gruppenspezifischen Genauigkeitslücken. Für die Markenführung bedeutet dies, dass kuratierte Prompt-Leitfäden, Reviews sowie dokumentierte Freigaben nicht optional sind, sondern als Qualitätssicherung wirken. Transparenzanforderungen bzw. Kennzeichnungspflichten müssen demnach praktikabel in Produktions- und Veröffentlichungsroutinen verankert werden, ohne die Markenidentität zu gefährden. Überdies unterstreichen die A/B-Tests die Kontextabhängigkeit: Während KI-Creatives ohne Hinweis keinen klaren Vorteil zeigten, war mit expliziter Kennzeichnung ein Effizienzgewinn zu beobachten.

Systemintegration und Prozessreife bleiben indes eine strukturelle Herausforderung. So entfalten KI-gestützte Workflows ihren Nutzen erst, wenn Redaktions-, Community-, Daten- und Anzeigenprozesse technisch und organisatorisch gekoppelt sind; ansonsten führen fehlende Standardschnittstellen und unklare Übergaben zwischen Kreation, Datenanalyse und Media zu Medienbrüchen, die Automatisierungsgewinne neutralisieren. Für Caramba ist die nach dem MBO gewonnene Agilität Chance und Risiko zugleich. Schnellere Entscheidungen beschleunigen Pilotierungen, erfordern aber umso stärker verbindliche Checkpoints für Brand-Safety, Versionierung und Compliance, damit Experimente nicht an der internen Anschlussfähigkeit scheitern.

Des Weiteren birgt die kreative Homogenisierung bei generativer Produktion mittel- bis langfristige Risiken in Hinblick auf Differenzierung und Markenprägnanz. Der Theorie- und Praxisstand verweist darauf, dass generative Pipelines zwar die individuelle Kreativität steigern, auf Portfolioebene jedoch die Varianz und Neuartigkeit senken können, wenn wiederholt auf ähnliche Muster trainiert und publiziert wird. Für eine Traditionsmarke mit klaren Identitätsankern ist deshalb eine redaktionelle Gegensteuerung nötig: Markenstil, visuelle Leitplanken müssen entsprechend gesetzt werden, damit Effizienzgewinne nicht auf Kosten der Unverwechselbar-

keit gehen. Auch auf der Ausspielungsseite sind Risiken zu adressieren: Plattformseitige Optimierung kann unbeabsichtigt Zielgruppen verzerren oder einzelne Motive überbetonen, wenn KPIs und regelmäßige A/B-Validierungen fehlen.

Hinzu kommt ein methodisches Risiko: Die in dieser Arbeit eingesetzten A/B-Tests liefern zwar wesentliche, aber gleichzeitig auch kontextspezifische Evidenz. Kurze Laufzeiten, begrenzte Budgets und wenige Testarme erhöhen die Gefahr von Zufallseffekten oder Überinterpretationen. Folglich sind die beobachteten Effizienzgewinne unter Kennzeichnung als Hypothesen-Anker für weitere, strikt kontrollierte Tests zu verstehen, nicht als allgemeine Leistungszusage. Erst eine feste Experimentierroutine mit klaren KPIs, Rollbacks und dokumentierten Abbruchkriterien verbindet die im Theorieteil geforderte Kausalität mit der im Audit angemahnten Prozessdisziplin.

5.4 Content, Kampagnen- und Werbeanzeigenmanagement

Die Steuerung basiert auf einem Soll-KPI-Rahmen, der Oberziele in überprüfbare Format- und Kampagnenziele übersetzt. Für organische Inhalte werden Reichweite, Interaktionen und Engagement als Qualitätsmaße festgelegt, für Paid-Ausspielungen fungiert die Reichweite pro Budgeteinheit als primäre Effizienzgröße - ergänzt um CPM als Kostengrenzwert und Frequency als Sättigungs-KPI. Interaktionen dienen entsprechend der qualitativen Einordnung, ohne das Awareness-Ziel zu ersetzen. Die im A/B-Setting verwendete Logik mit OEC, CPM und Frequency wird so zur Standard-Referenz für die Bewertung künftiger Creatives, Platzierungen und Zeitfenster. Dabei werden Effekte nur qualitativ berichtet und entlang vordefinierter Schwellen interpretiert. Diese Rahmung schließt die im Audit konstatierte Ziel-Mess-Lücke und verhindert eine Steuerung über uneinheitliche Proxys.

Im Werbeanzeigenmanagement wird indes eine feste Experimentierroutine etabliert. Diese repliziert die in dieser Arbeit eingesetzte Methodik aus: personenbasierter Randomisierung, klarer Trennung der Testzellen, statisch versionierten Creatives, identischen Rahmenbedingungen und einem vorab definierten Auswertungsplan mit KPIs. Hypothesen werden sequenziell geprüft, beginnend bei Formatrollen und Motivvarianten, gefolgt von Platzierungsbündeln und Zeitfenstern. Die Befunde aus den beiden A/B-Phasen werden dann als interne Evidenz operationalisiert: Ohne Kennzeichnung zeigten KI-Assets keinen robusten Vorteil gegenüber manuellen Pendants. Mit explizitem Hinweis „Mit KI generiert.“ ergaben sich wiederum Effizienzgewinne bei CPM und Reichweite pro Budgeteinheit. Daraus folgt, die Kennzeichnung als transparente Standardoption zu prüfen und kontextabhängig einzusetzen, anstatt generative

Assets pauschal zu bevorzugen. Advantage-basierte Automatisierung wird entsprechend genutzt, wo sie die Testlogik nicht unterläuft. Jede dynamische Modifikation bleibt zudem dokumentiert und wird nur innerhalb klarer KPIs zugelassen.

Des Weiteren stellt die Produktions- und Governance-Schicht sowohl Nachvollziehbarkeit als auch Marken-Safety sicher. Creative-Protokolle erfassen Prompts, Versionen und Freigaben. Ein dokumentierter Review-Pfad mit fachlicher, rechtlicher und markenbezogener Prüfung verankert „Human-in-the-Loop“ verbindlich und adressiert Authentizitäts- und Fairness-Risiken. Synthetische Anteile werden entsprechend der im Manuskript adressierten Kennzeichnungsanforderungen sichtbar gemacht und in eine Kommunikationslogik eingebettet, die KI als Werkzeug erklärt, ohne die Traditionsmarke zu relativieren. Daten- und Modell-Governance bündeln zudem Qualitätsregeln, Zugriffsrechte und Eskalationslogiken. Schnittstellen zwischen Redaktion, Community, Datenanalyse und Media werden standardisiert, damit Automatisierungsgewinne nicht an Medienbrüchen verpuffen. Flankierend sollten Schulungen zu Prompt-Praktiken, Kreativ-Variation, Datenschutz und Auswertung aufgesetzt werden, um Kompetenzen teamweit zu verteilen und Abhängigkeiten von Einzelpersonen abzubauen.

In der Summe entsteht ein geschlossenes, lernendes System, das die Logik dynamischer Fähigkeiten operativ macht: Social Listening und Performance-Analysen liefern das Erkennen von experimentell validierten Kreativ- und Platzierungsportfolios. Für Caramba bedeutet dies, die Reichweite, Effizienz und Beziehungsqualität auf Instagram zugleich zu steigern und verlässlich zu steuern. Reels treiben darüber hinaus die Skalierung voran, während der Feed die Reputation konsolidiert. Kennzeichnung und „Human-in-the-Loop“ sichern die Glaubwürdigkeit; und UTM, Conversion-Tracking sowie die Commerce-Funktionen schließen die Messbrücke. Überdies verankern A/B-Routinen die entsprechende Kausalität in der täglichen Praxis. Dieses Zusammenspiel übersetzt die Agilität nach dem MBO in reproduzierbare Routinen und hält die Traditionsmarke auch im KI-gestützten Betrieb als nahbare, konsistente Problemlöserin präsent.

6 Diskussion

Die Ergebnisse zeichnen ein konsistentes Muster: Im Instagram-Audit erzielten Reels über den Zeitraum 28.09.2024-28.09.2025 im Mittel deutlich höhere Reichweiten (25,44 %) und Interaktionen, während der Feed beim Median-Engagement leicht vorn lag (3,84 % vs. 3,34 %). In den Meta-A/B-Tests zeigte Phase 1 ohne Kennzeichnung zwischen KI- und humaner Ausspielung weitgehende Parität: CPM 1,45 vs. 1,50 identisches OEC von rund 667 Frequenz jeweils um 1,0. In Phase 2 mit dem Hinweis „Mit KI generiert." verbesserte die KI-Variante die Reichweite (158. 412 vs. 144 866), CPM (1,53 vs. 1,69) und OEC (646 vs. 592) bei unveränderter Frequenz (~ 1,01), sodass Transparenzsignale die Effizienz nicht minderten und mit leichten Zugewinnen korrelierten (vgl. Tab. 2).

Zusammengenommen stützen die Befunde den Theorierahmen, wonach KI datengetriebene Routinen ermöglicht und unter „Human-in-the-Loop"-Prämissen skaliert, gleichzeitig jedoch die Authentizität durch Kennzeichnung abgesichert werden muss (vgl. Kap. 4 - 5). Operativ impliziert das Audit einen zweigleisigen Content-Pfad bestehend aus: Reels als Reichweitenmotor für Awareness sowie Feed-Beiträgen zur Stabilisierung relativer Interaktionstiefe. Der Befund fehlender Soll-KPIs, nicht implementierter UTM- und Conversion-Messung, kaum genutzter Commerce-Funktionen sowie Einzelverantwortung ohne dokumentierte Prozesse verhindert jedoch belastbare Lernschleifen und die Ableitung dynamischer Budget- und Kreativregeln (vgl. Kap. 3.3.2).

Strategisch deutet die Kombination aus MBO-bedingter Agilität und Dualität bezüglich B2C/B2B darauf hin, dass KI als Ermöglicher dynamischer Fähigkeiten wirken kann. Dies gilt jedoch nur, sofern Datenqualität, Integration und Governance zuerst adressiert und Automatisierungen explizit mit Marken-Glaubwürdigkeit balanciert werden. Überdies legen die A/B-Ergebnisse nahe, dass eine klare Kennzeichnung die im Theorierahmen diskutierten Authentizitätsrisiken entschärfen kann, ohne Reichweiten- oder Effizienzeinbußen zu verursachen. Gleichwohl bleibt Kausalität aufgrund des Designs begrenzt.

In der Validität sind indes mehrere Einschränkungen zu beachten: Die Tests fokussieren ein kurzes Awareness-Fenster (11.-25.10.2025) mit niedriger Kontaktfrequenz, sodass Sättigungseffekte, kreative Verschleißdynamiken oder Überschneidungen mit externen Ereignissen nicht erfasst werden. Darüber hinaus sind OEC-Unterschiede ohne Conversion-Tracking und Ziel-Attribution nur als Effizienzproxys interpretierbar. Fehlende UTM-Parameter und Commerce-Signale begrenzen überdies die interne Validität. Die Generalisierbarkeit auf B2B-

Zielgruppen bleibt zudem offen. Auch im Audit können saisonale und inhaltsgetriebene Störfaktoren vorliegen, die ohne definierte Soll-KPIs und Prozessdokumentation schwer zu isolieren sind. Gleichwohl sind die Muster zwischen Audit und A/B-Test konsistent: Formate mit hoher Kurzvideo-Affinität steigern demnach die Reichweite, und KI-gestützte Aussteuerung schneidet unter Offenlegung mindestens gleich gut ab.

Die Stärken der Untersuchung liegen vor allem im experimentellen Design. Das A/B-Test Design entspricht den Empfehlungen für Online Experimente, die eine kausale Zuordnung ermöglichen und durch KPIs wie Frequency mögliche Nebenwirkungen überwachen. Auch die Entscheidung, den Hinweis „Mit KI generiert." zu testen, adressiert aktuelle regulatorische Anforderungen und ermöglicht eine explorative Untersuchung.

Gleichzeitig sind die Grenzen der Ergebnisse zu beachten. So ist z. B. die Stichprobenbasis begrenzt: Es wurden zwei Anzeigengruppen pro Experiment über jeweils sieben Tage untersucht. Demnach sind die Ergebnisse nur für den untersuchten Awareness Use Case generalisierbar. Zudem können die Leistungsunterschiede auch auf inhaltliche Faktoren zurückgehen, etwa auf Bildästhetik oder textliche Gestaltung, die zwischen KI- und Human-Assets variierten. Wiederum der CPM-Rückgang in Phase 2 deutet darauf hin, dass die Transparenz die Performance begünstigte. Ob dies auf wahrgenommene Innovationskompetenz oder auf Zufall zurückzuführen ist, lässt sich indes nicht abschließend klären.

In Summe stützen die Befunde die Rolle von KI als leistungsfähigem Hebel im Social-Media- und Werbeanzeigenmanagement von Caramba, sofern Messlogik, Daten- und Prozess-Governance sowie Kennzeichnungspflichten konsequent umgesetzt werden. Diese sollten außerdem durch menschliche Kontrolle auf Markenpassung abgesichert werden. Unter diesen Bedingungen kann KI Agilität in skalierbare Routine überführen, ohne die Authentizität der Traditionsmarke zu unterlaufen.

7 Fazit und Ausblick

7.1 Zusammenfassung und Reflexion der Ergebnisse

Die Thesis zeigt, dass Social-Media-Management als dynamische Fähigkeit durch KI gezielt verstärkt werden kann. Dies ist jedoch nur möglich, sofern datengetriebene Routinen wie Social Listening, Sentiment-Analyse und Automatisierung mit klaren Leitplanken aus „Human-in-the-Loop“, belastbarer Data Governance und der Kennzeichnung von KI-Inhalten verknüpft werden. Für Caramba eröffnet dies nach dem MBO seit September 2024 die Chance, agile Pilotierungen im dualen B2C/B2B-Set-up schneller zu realisieren und in skalierbare Prozesse zu überführen.

Die Forschungsfrage lautete: Wie kann KI im Werbeanzeigenmanagement angewandt werden, um eine Effizienzsteigerung im Social-Media-Management zu erzielen, und wie müssen hierfür Content-Erstellung, Kampagnensteuerung und Werbeanzeigenmanagement angepasst werden?

Anhand von drei Kernaussagen können die Ergebnisse zusammengefasst werden:

- KI ermöglicht eine deutliche Beschleunigung der Variantenbildung und Kampagnensteuerung.
- Die Wirksamkeit bleibt ohne belastbares Messfundament begrenzt.
- Authentizität und Fairness sind nur mit expliziter menschlicher Steuerung und transparenter Kennzeichnung dauerhaft sicherzustellen.

Das Instagram-Audit (Kap. 3.3.2) bestätigt die Plattformlogik: Reels generieren demnach höhere Reichweiten und Interaktionen, während Feed-Posts ein leicht höheres Engagement aufweisen. Diese Divergenz impliziert für Caramba keine einfache Entweder-oder-Entscheidung, sondern die automatisierte Verwendung beider Formate entlang klar definierter Ziele. Die identifizierten Lücken bei Soll-KPIs, Attribution durch fehlende UTM- und Conversion-Set-ups, bei Commerce-Features sowie in der Governance durch Einzelverantwortung und das Fehlen eines institutionalisierten Dashboards markieren entsprechend einen zentralen Engpass. Ohne verlässliche Zuordnung von Touchpoints zu Ergebnissen kann weder die kreative Leistung noch die Medieneffizienz valide bewertet werden. So wird die im Theorierahmen geforderte datenbasierte Adaptivität operativ ausgebremst.

Die A/B-Tests schärfen dieses Bild. In Phase 1 ohne Kennzeichnung zeigten KI- und Human-Creatives ungefähr Parität, was darauf hindeutet, dass KI-gestützte Kreativvarianten zwar die Baseline menschlicher Produktion erreichen, ihre Mehrwerte aber erst in den skalierenden

Automatisierungen sichtbar werden. In Phase 2 führte die transparente Kennzeichnung „Mit KI generiert." bei vergleichbarer Frequency zu Effizienzgewinnen bei CPM und OEC. Für Caramba ist daraus abzuleiten, dass Transparenz unter Awareness-Zielen kein Leistungsrisiko darstellt und die Reichweite pro Budget erhöhen kann, wenn KI-Varianten mit Advantage-Logiken und einer disziplinierten A/B-Kadenz kombiniert werden. Demgegenüber bleibt reine Tool-Nutzung ohne Automatisierung und klare Hypothesen wirkungsschwach.

Gleichzeitig treten Grenzen hervor: kurze Testhorizonte, der Fokus auf Awareness, ein Markt (Handel) und ein Kanal (Instagram) limitieren die Generalisierbarkeit. Kreative Homogenisierung ist zudem ein Risiko, wenn KI-Outputs ohne Kontrolle angewandt werden. Ohne belastbare Data Governance mit Qualitätssicherung, Integration und Rollenklärung drohen Messfehler, und ohne „Human-in-the-Loop" sind Markenidentität und Fairness gefährdet. Insgesamt stützt die Arbeit die These, dass KI als Ermöglicher funktioniert, sofern Caramba ein messbares Fundament etabliert, Governance und Prozesse professionalisiert und Transparenz systematisch verankert.

Damit lässt sich die Forschungsfrage wie folgt beantworten: KI kann im Werbeanzeigenmanagement Effizienzsteigerungen im Rahmen des Social-Media-Managements bewirken. Voraussetzung ist erstens, dass die Content-Erstellung auf kuratierte KI-Variantenbildung ausgerichtet wird und dass klare Hypothesen, eine entsprechende Kennzeichnung sowie kreative Diversität gewährleistet werden. Zweitens muss die Kampagnensteuerung Advantage-Logiken, rollierende A/B-Tests sowie OEC, CPM und Frequency als harte Entscheidungsgrößen nutzen. Drittens ist das Werbeanzeigenmanagement durch saubere Attribution, standardisierte UTM- und Conversion-Set-ups, ein institutionalisiertes Dashboard sowie „Human-in-the-Loop" und Data Governance abzusichern. Unter diesen Voraussetzungen werden die beobachteten Effizienzgewinne reproduzierbar und in eine dynamische Fähigkeit überführbar; ohne sie bleiben KI-Effekte punktuell und nicht verlässlich skalierbar.

7.2 Ausblick und weiterführender Forschungsbedarf

Der Weg zu einem belastbaren KI-augmentierten Social-Media-Management führt für Caramba über ein schrittweises Vorgehen: Zunächst muss ein messbares Fundament geschaffen werden, das die Attribution, Commerce-Funktionalitäten und ein konsistentes Set von KPIs sicherstellt. Darauf aufbauend kann KI systematisch in die Variantenbildung und Kampagnensteuerung integriert werden - flankiert von Advantage-Logiken, einer disziplinierten A/B-Teststruktur und klarer Kennzeichnung. Governance und „Human-in-the-Loop" sichern

dabei Authentizität und Fairness, während Qualifizierungsmaßnahmen Akzeptanz und Handlungsfähigkeit im Team erhöhen. Entsprechend deuten die A/B-Befunde darauf hin, dass Transparenz gegenüber Nutzern die Effizienz im Awareness-Zielrahmen nicht mindert und unter Bedingungen konsistenter Automatisierung sogar Vorteile erzeugen kann. Für die duale B2C/B2B-Ausrichtung bedeutet dies: KI soll nicht nur den Output beschleunigen, sondern vor allem die lernfähige, markenkonforme Anpassung an Segmente, Formate und Ziele ermöglichen.

Für Caramba ergibt sich daraus ein priorisiertes Vorgehen, das zunächst ein institutionalisiertes Messfundament herstellt: Ein verbindlicher KPI-Rahmen mit OEC, CPM und Frequency ist einzuführen; dabei sind Soll-KPIs je Zielsetzung zu definieren und in einem zentralen Dashboard abzubilden. Verantwortlichkeiten sowie feste Review-Rhythmen stellen die kontinuierliche Steuerung sicher. Darauf aufbauend sind Attribution und Datenintegration abzusichern, indem UTM-Standards und ein belastbares Conversion-Set-up verpflichtend verankert und die Datenflüsse aus Plattformen und Webanalytik so zusammengeführt werden, dass Reichweite, Engagement und Commerce-Signale kohärent ausgewertet werden können. Parallel müssen Commerce-Features aktiviert werden; daher sollten native Funktionen und produktnahe Touchpoints gezielt getestet und systematisch an Reels und Feed angebunden werden, um den Übergang von Aufmerksamkeit zu Interaktion und Kaufabsicht messbar zu gestalten.

Indes ist die KI-gestützte Variantenbildung als kuratierte Automatisierung anzulegen: Kreativvarianten werden mit Advantage-Logiken kombiniert, Hypothesen vorab präzisiert und A/B-Tests werden etabliert. Entscheidungen sind überdies konsequent an OEC, CPM und Frequency zu koppeln. Transparenz wird diesbezüglich durch eine standardisierte Kennzeichnung gesichert, indem die Formulierung „Mit KI generiert.“ als verbindlicher Bestandteil für KI-Creatives festgelegt und in einem Leitfaden zu Einsatz, Platzierung, Ausnahmen und Freigabeprozess dokumentiert wird. Flankierend stärkt Caramba die Data Governance und Model Governance durch definierte Qualitätsprüfungen der Daten bezogen auf Vollständigkeit und Konsistenz, durch Prompt- und Asset-Dokumentation, klar geregelte Freigabe-Workflows und Kontrollen. Dabei fungiert der „Human-in-the-Loop“ als obligatorische Kontrollinstanz. Schließlich sind Qualifizierung und Akzeptanz zu fördern, indem Rollen und Kompetenzen entlang der neuen Routinen geschärft sowie Schulungen zu KPI-Lesart, Attributionslogik und KI-Kurationspraxis durchgeführt werden und ein kuratierter Kreativpool mit Best-Practice-Beispielen aufgebaut wird.

Der weiterführende Forschungsbedarf umfasst die kontextabhängige Wirkung der Kennzeichnung „Mit KI generiert." - insbesondere mit Blick auf unterschiedliche Zielrahmen wie Awareness gegenüber Interaktion sowie segment-spezifische Moderatoren wie Format, Motiv und Tonalität. Hierbei bezieht sich die Übertragbarkeit auf die Analyse der - im B2C-geprägten Instagram-Umfeld - beobachteten Effekte auf B2B-Kontexte und andere Plattformen, insbesondere hinsichtlich der Reichweitenqualität, der Entscheidungsrollen und der erforderlichen Content-Tiefe. Zudem bedarf es praxistauglicher Verfahren für Datenkontrollen, die kreative Homogenisierung fortlaufend erkennen sowie begrenzen. Zugleich müssen Fairness und Markenpassung bei steigender KI-Automatisierung abgesichert werden. Eine experimentelle Robustheit ist überdies durch längere Testhorizonte mit ausreichender Teststärke und klaren KPIs zu gestalten, um Stabilität und Replizierbarkeit über Zeit, Saisonalität und Budgetniveaus zu prüfen. Des Weiteren sollte untersucht werden, wie Commerce-Signale substanziell in die KPI-Logik integriert werden können und welche Attributionsketten zwischen Content, Anzeigenkontakt und nachgelagerten Interaktionen belastbar abgebildet werden. Zudem sollten Automatisierungslogiken erforscht werden, die das Zusammenspiel und die Dosierung von A/B-Tests (wie die Variantenpool-Größe und kuratorische Regeln) so austarieren, dass Effizienzgewinne gesichert werden, ohne die kreative Vielfalt und die Markenidentität zu verengen.

Im Gesamtbild eröffnet die Kombination aus robustem Messfundament, verankerter Governance und gezielter KI-Automatisierung Caramba einen klaren Entwicklungspfad - von fragmentarischer Nutzung zu einer dynamischen Fähigkeit, die Reichweite, Effizienz und Markenpassung verbindet. Gelingt die konsequente Umsetzung, kann KI vom reinen Produktionsbeschleuniger zum verlässlichen Hebel für lernfähiges, markenkonformes Wachstumsmarketing werden.

Literaturverzeichnis

Adobe (2025), Adobe Firefly for Enterprise - Core and Web App. Security Fact Sheet, o. E. Quelle: https://www.adobe.com/content/dam/cc/en/trust-center/ungated/whitepapers/creative-cloud/adobe-firefly-fact-sheet.pdf, Zugriffsdatum: 27.09.2025.

Agarwal, O. und Nenkova, A. (2022), Temporal Effects on Pre-trained Models for Language Processing Tasks, in: *Transactions of the Association for Computational Linguistics*, 10, S. 904-921.

Aguirre, E., Mahr, D., Grewal, D., de Ruyter, K. und Wetzels, M. (2015), Unraveling the personalization paradox: The effect of information collection and trust-building strategies on online advertisement effectiveness, in: *Journal of Retailing*, 91(1), S. 34-49. https://doi.org/10.1016/j.jretai.2014.09.005

AlDahoul, N., Rahwan, T. und Zaki, Y. (2025), AI-generated faces influence gender stereotypes and racial homogenization, in: *Scientific Reports*, 15, 14449, S. 1-15. https://doi.org/10.1038/s41598-025-99623-3

Aramburu, M. J., Berlanga, R. und Lanza-Cruz, I. (2024), A Data Quality Multidimensional Model for Social Media Analysis, in: *Business & Information Systems Engineering*, 66, S. 667-689. https://doi.org/10.1007/s12599-023-00840-9

Audrezet, A., de Kerviler, G. und Moulard, J. G. (2020), Authenticity under threat: When social media influencers need to go beyond self-presentation, in: *Journal of Business Research*, 117, S. 557-569. https://doi.org/10.1016/j.jbusres.2018.07.008

Baijens, J., Huygh, T. und Helms, R. W. (2022), Establishing and theorising Data analytics governance: a descriptive framework and a VSM-based view, in: *Journal of Business Analytics*, 5(1), S. 101-122. https://doi.org/10.1080/2573234X.2021.1955021

Bender, E. M., Gebru, T., McMillan-Major, A. und Mitchell, S. (2021), On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?, in: *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAccT '21)*, S. 610-622. https://doi.org/10.1145/3442188.3445922

Bleier, A. und Eisenbeiss, M. (2015), Personalized Online Advertising Effectiveness: The Interplay of What, When, and Where, in: *Marketing Science*, 34(5), S. 669-688. https://doi.org/10.1287/mksc.2015.0930

Brynjolfsson, E., Li, D. und Raymond, L. (2023), Generative AI at Work. NBER Working Paper 31122, Cambridge.

Caramba GmbH (2025), Über uns, Duisburg. Quelle: https://www.caramba.de/ueber-uns/, Zugriffsdatum: 02.09.2025.

Chatterji, A., Cunningham, T., Deming, D., Hitzig, Z., Ong, C., Shan, C. und Wadman, K. (2025), How People Use ChatGPT. OpenAI, Duke University & Harvard University Working Paper, o. E. Quelle: https://cdn.openai.com/pdf/a253471f-8260-40c6-a2cc-aa93fe9f142e/economic-research-chatgpt-usage-paper.pdf, Zugriffsdatum: 27.09.2025.

CHEManager (2024), Caramba wird konzernunabhängig, o. E. Quelle: https://chemanager-online.com/de/news/caramba-wird-konzernunabhaengig, Zugriffsdatum: 02.09.2025.

Cristofaro, M. und Giardino, P. L. (2025), Surfing the AI waves: the historical evolution of artificial intelligence in management and organizational studies and practices, in: *Journal of Management History*, S. 1-27. https://doi.org/10.1108/JMH-01-2025-0002

Crowe BPG (2024), Crowe advises on the Management Buyout (MBO) of the Caramba business and the Caramba brand, o. E. Quelle: https://www.crowe-bpg.de/en/news/2024-10-crowe-advises-management-buyout-mbo-caramba-business-and-caramba-brand, Zugriffsdatum: 02.09.2025.

Cubric, M. (2020), Drivers, barriers and social considerations for AI adoption in business and management: A tertiary study, in: *Technology in Society*, 62, S. 5-11. https://doi.org/10.1016/j.techsoc.2020.101257

Cui, W., Liu, M. J. und Yuan, R. (2025), Exploring the Integration of Generative AI in Advertising Agencies: A Co-Creative Process Model for Human-AI Collaboration, in: *Journal of Advertising Research*, 65(2), S. 167-189. https://doi.org/10.1080/00218499.2024.2445362

Davenport, T., Guha, A., Grewal, D. und Bressgott, T. (2020), How artificial intelligence will change the future of marketing, in: *Journal of the Academy of Marketing Science*, 48, S. 24-42. https://doi.org/10.1007/s11747-019-00696-0

Davenport, T. H. und Ronanki, R. (2018), Artificial Intelligence for the Real World, in: *Harvard Business Review*, 96(1), S. 108-116.

De Keyzer, F., Buzeta, C. und Lopes, A. I. (2024), The role of well-being in consumer's responses to personalized advertising on social media, in: *Psychology and Marketing*, 41(6), S. 1206-1222. https://doi.org/10.1002/mar.21977

Deng, A. und Shi, X. (2016), Data Driven Metric Development for Online Controlled Experiments: Seven Lessons Learned, in: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, S. 1-3. https://doi.org/10.1145/2939672.2939700

de Vries, L., Gensler, S. und Leeflang, P. S. H. (2012), Popularity of Brand Posts on Brand Fan Pages: An Investigation of the Effects of Social Media Marketing, in: *Journal of Interactive Marketing*, 26(2), S. 83-91. https://doi.org/10.1016/j.intmar.2012.01.003

Doshi, A. R. und Hauser, O. P. (2024), Generative AI enhances individual creativity but reduces the collective diversity of novel content, in: *Science Advances*, 10(28), eadn5290, S. 1-9. https://doi.org/10.1126/sciadv.adn5290

Drydakis, N. (2022), Artificial Intelligence and Reduced SMEs' Business Risks. A Dynamic Capabilities Analysis During the COVID-19 Pandemic, in: *Information Systems Frontiers*, 24, S. 1223-1247. https://doi.org/10.1007/s10796-022-10249-6

Eisenhardt, K. M. und Martin, J. A. (2000), Dynamic capabilities: what are they?, in: *Strategic Management Journal*, 21(10/11), S. 1105-1121. https://sms.onlinelibrary.wiley.com/doi/abs/10.1002/1097-0266%28200010/11%2921%3A10/11%3C1105%3A%3AAID-SMJ133%3E3.0.CO%3B2-E?, Zugriffsdatum: 24.10.2025.

Europäische Union (2024), Verordnung (EU) 2024/1689 des Europäischen Parlaments und des Rates vom 13. Juni 2024 über künstliche Intelligenz (AI Act), in: *Amtsblatt der Europäischen Union, L 2024/1689, 12.07.2024*, S. 82-83.

EY (2024), EY European AI Barometer 2024, o. E. Quelle: https://www.ey.com/de_de/insights/ai/ey-european-ai-barometer-2024, Zugriffsdatum: 18.10.2025.

Fan, W. & Gordon, M. D. (2014): The Power of Social Media Analytics. *Communications of the ACM*, 57(6), S. 74–81. doi:10.1145/2602574.

Farris, P. W., Bendle, N. T., Pfeifer, P. E. und Reibstein, D. J. (2009), *Key Marketing Metrics: The 50+ Metrics Every Manager Needs to Know*, Pearson Education, Harlow.

Farris, P. W., Bendle, N. T., Pfeifer, P. E. und Reibstein, D. J. (2006), *Marketing Metrics: The Definitive Guide to Measuring Marketing Performance*, Upper Saddle River, Pearson Education, NJ.

Federal Trade Commission (2014), *Data Brokers: A Call for Transparency and Accountability*, Washington, DC.

Felix, R., Rauschnabel, P. A. und Hinsch, C. (2017), Elements of strategic social media marketing: A holistic framework, in: *Journal of Business Research*, 70, S. 118-126. https://doi.org/10.1016/j.jbusres.2016.05.001

Ferrara, E., Varol, O., Davis, C., Menczer, F. und Flammini, A. (2016), The rise of social bots, in: *Communications of the ACM*, 59(7), S. 96-104. https://doi.org/10.1145/2818717

Gandomi, A. und Haider, M. (2015), Beyond the hype: Big data concepts, methods, and analytics, in: *International Journal of Information Management*, 35(2), S. 137-144. https://doi.org/10.1016/j.ijinfomgt.2014.10.007

Gebru, T., Morgenstern, J., Vecchione, B., Wortman Vaughan, J., Wallach, H., Daumé III, H. und Crawford, K. (2021), Datasheets for Datasets, in: *Communications of the ACM*, 64(12), S. 86-92. https://doi.org/10.1145/3458723

Geitz, M. (2025), How Kraft Heinz Is Using GenAI to Reimagine the Future of Creative Content, o. E. Quelle: https://www.forrester.com/blogs/how-kraft-heinz-is-using-genai-to-re-imagine-the-future-of-creative-content/, Zugriffsdatum: 17.09.2025.

Geng, T., Lin, X., Nair, H. S., Hao, J., Xiang, B. und Fan, S.(2021), Comparison Lift: Bandit-based Experimentation System for Online Advertising, in: *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(18), S. 15117-15124. https://doi.org/10.1609/aaai.v35i17.17775

Gigli, M. und Stella, F. (2025), Multi-armed bandits for performance marketing, in: *International Journal of Data Science and Analytics*, 20, S. 151-165. https://doi.org/10.1007/s41060-023-00493-7

Gordon, B. R., Zettelmeyer, F., Bhargava, N. und Chapsky, D. (2019), A Comparison of Approaches to Advertising Measurement: Evidence from Big Field Experiments at Facebook, in: *Marketing Science*, 38(2), S. 193-225. https://doi.org/10.1287/mksc.2018.1135

Grewal, D., Satornino, C. B., Davenport, T. und Guha, A. (2025), How generative AI is shaping the future of marketing, in: *Journal of the Academy of Marketing Science*, 53, S. 702-722. https://doi.org/10.1007/s11747-024-01064-3

Gooljar, V. (2024), Sentiment-based predictive models for online purchases in the era of marketing 5.0: a systematic review, in: *Journal of Big Data*, 11, Article 107, S. 23-24. Quelle: https://doi.org/10.1186/s40537-024-00947-0

Gururangan, S., Marasović, A., Swayamdipta, S., Lo, K., Beltagy, I., Downey, D. und Smith, N. A. (2020), Don't Stop Pretraining: Adapt Language Models to Domains and Tasks, in: *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, S. 8342-8360. https://doi.org/10.18653/v1/2020.acl-main.740

Haefner, N., Parida, V., Gassmann, O. und Wincent, J. (2023), Implementing and scaling artificial intelligence: A review, framework, and research agenda, in: *Technological Forecasting and Social Change*, 197, Art. 122878, S. 1-22. https://doi.org/10.1016/j.techfore.2023.122878

Hartmann, J. und Netzer, O. (2023), Natural Language Processing in Marketing, in: Toubia, O. und Sudhir, K. (Hrsg.): *Artificial Intelligence in Marketing. Review of Marketing Research*, S. 191-215. https://doi.org/10.1108/S1548-643520230000020011

Hartmann, J., Heitmann, M., Siebert, C. und Schamp, C. (2023), More than a Feeling: Accuracy and Application of Sentiment Analysis, in: *International Journal of Research in Marketing*, 40(1), S. 75-87. https://doi.org/10.1016/j.ijresmar.2022.05.005

Hartmann, J., Exner, Y. und Domdey, S. (2025), The power of generative marketing: Can generative AI create superhuman visual marketing content?, in: *International Journal of Research in Marketing*, 42(1), S. 13-31. https://doi.org/10.1016/j.ijresmar.2024.09.002

Heitmann, M. (2024): Generative AI for Marketing Content Creation: New Rules for an Old Game. *NIM Marketing Intelligence Review*, 16(1), 10–17. https://doi.org/10.2478/nimmir-2024-0002

Herhausen, D., Bernritter, S. F., Ngai, E. W. T., Kumar, A. und Delen, D. (2024), Machine learning in marketing: Recent progress and future research directions, in: *Journal of Business Research,* 170, Art. 114254, S. 1-11. https://doi.org/10.1016/j.jbusres.2023.114254

Hermann, E. (2022), Leveraging artificial intelligence in marketing for social good—An ethical perspective, in: *Journal of Business Ethics*, 179, S. 43-61. https://doi.org/10.1007/s10551-021-04843-y

High-Level Expert Group on Artificial Intelligence (AI HLEG) (2019): *Ethics Guidelines for Trustworthy AI*. Brussels: European Commission. Online verfügbar als PDF: https://www.europarl.europa.eu/cmsdata/196377/AI%20HLEG_Ethics%20Guidelines%20for%20Trustworthy%20AI.pdf

Hoffmann, L. und Zerres, C. (2017), Prozess und Methoden des Social Media Monitorings (Arbeitspapiere für Marketing und Management, Nr. 18), Offenburg.

Huang, M.-H. und Rust, R. T. (2021), A strategic framework for artificial intelligence in marketing, in: *Journal of the Academy of Marketing Science*, 49(1), S. 30-50. https://doi.org/10.1007/s11747-020-00749-9

Huang, M.-H. und Rust, R. T. (2018), Artificial intelligence in service, in: *Journal of Service Research*, 21(2), S. 155-172. https://doi.org/10.1177/1094670517752459

Huang, S., Aral, S., Hu, Y. J. und Brynjolfsson, E. (2020), Social Advertising Effectiveness Across Products: A Large-Scale Field Experiment, in: *Marketing Science*, o. Jg., o. Heft, S. 1033-1201. https://doi.org/10.1287/mksc.2020.1240

IAB (Interactive Advertising Bureau) & PwC (2023): *Internet Advertising Revenue Report – Full-year 2022 results.* April 2023, S. 16 -18. Online verfügbar unter: https://www.iab.com/wp-content/uploads/2023/04/IAB_PwC_Internet_Advertising_Revenue_Report_2022.pdf

IFH KOELN/ECC KOELN (2025), Implementierung von KI: Daten und Mitarbeitende sind größte Herausforderungen. Pressemitteilung, 26.03.2025, o. E.

Imana, B.; Korolova, A.; Heidemann, J. (2025): Auditing for Bias in Ad Delivery Using Inferred Demographic Attributes. In: *Proceedings of the 2025 ACM Conference on Fairness, Accountability, and Transparency (FAccT '25)*, Athens, 23.–26. 06. 2025. New York: ACM, S. 2640–2656. DOI: 10.1145/3715275.3732172

Israfilzade, K. (2024), Benefits and Risks of Generative AI in Content Marketing, in: *Proceedings of the 10th International European Congress on Advanced Studies in Basic Sciences*, Amsterdam, S. 557-562. https://doi.org/10.5281/zenodo.13731679

Kallmuenzer, A., Mikhaylov, A., Chelaru, M. und Czakon, W. (2025), Adoption and performance outcome of digitalization in small and medium-sized enterprises, in: *Review of Managerial Science*, 19, S. 2011-2038. https://doi.org/10.1007/s11846-024-00744-2

Kanuri, V. K., Hughes, C. und Hodges, B. T. (2024), Standing out from the crowd: When and why color complexity in social media images increases user engagement, in: *International Journal of Research in Marketing*, 41(2), S. 174-193. https://doi.org/10.1016/j.ijresmar.2023.08.007

Kanuri, V. K., Chen, Y. und Sridhar, S. (2018), Scheduling content on social media: Theory, evidence, and application, in: *Journal of Marketing,* 82(6), S. 1-17.

Kaplan, A. M. und Haenlein, M. (2010), Users of the world, unite! The challenges and opportunities of social media, in: *Business Horizons*, 53(1), S. 59-67. https://doi.org/10.1016/j.bushor.2009.09.003

Kapoor, A. und Kumar, M. (2025), Frontiers: Generative AI and Personalized Video Advertisements, in: *Marketing* Science, 44(4), S. 733-747. https://doi.org/10.1287/mksc.2023.0494

Kietzmann, J. H., Hermkens, K., McCarthy, I. P. und Silvestre, B. S. (2011), Social media? Get serious! Understanding the functional building blocks of social media, in: *Business Horizons*, 54(3), S. 243-251. https://doi.org/10.1016/j.bushor.2011.01.005

Kohavi, R., Tang, D. und Xu, Y. (2020), *Trustworthy Online Controlled Experiments: A Practical Guide to A/B Testing*, Cambridge: University Press.

Kohavi, R., Henne, R. und Sommerfield, D. (2007), Practical Guide to Controlled Experiments on the Web: Listen to Your Customers Not to the HiPPO, in: *Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, S. 1-8. https://doi.org/10.1145/1281192.1281295

Kronrod, A. und Huber, J. (2019), Ad wearout wearout: How time can reverse the negative effect of frequent advertising repetition on brand preference, in: *International Journal of Research in Marketing*, 36(2), S. 306-324. https://doi.org/10.1016/j.ijresmar.2018.11.008

Kumar, V., Ashraf, A. R. und Nadeem, W. (2024), AI-powered marketing: What, where, and how?, in: *International Journal of Information Management*, 77, Art. 102783, S. 1-20. https://doi.org/10.1016/j.ijinfomgt.2024.102783

Lee, K.-C., Jalali, A. und Dasdan, A. (2013), Real time bid optimization with smooth budget delivery in online advertising, in: *ADKDD'13 (Workshop at KDD 2013)*, Chicago, IL, S. 1-9. https://doi.org/10.1145/2501040.2501979

Lewis, R. A. und Rao, J. M. (2015), The Unfavorable Economics of Measuring the Returns to Advertising, in: *The Quarterly Journal of Economics*, 130(4), S. 1941-1973. https://dx.doi.org/10.2139/ssrn.2367103

Liu, B. (2012), *Sentiment Analysis and Opinion Mining*, San Rafael, Morgan & Claypool Publishers CA. https://doi.org/10.2200/S00416ED1V01Y201204HLT016

Ma, L. und Sun, B. (2020), Machine learning and AI in marketing - Connecting computing power to human insights, in: *International Journal of Research in Marketing*, 37(3), S. 481-504. https://doi.org/10.1016/j.ijresmar.2020.04.005

Mariani, M. M., Perez-Vega, R. und Wirtz, J. (2022), AI in marketing, consumer research and psychology: A systematic literature review and research agenda, in: *Psychology & Marketing,* 39(4), S. 755-776. https://doi.org/10.1002/mar.21619

Marketing Maverick (2025), Details About “AI Ketchup” Marketing Strategy by Heinz, o. E. Quelle: https://marketingmaverick.io/p/ai-ketchup-marketing-strategy-by-heinz, Zugriffsdatum: 17.09.2025.

Meta (2024), Meta’s AI products just got smarter and more useful. Quelle: https://about.fb.com/news/2024/09/metas-ai-product-news-connect/ Zugriffsdatum: 24.10.2025.

Meta Business Help Center (o. D.) (A), About A/B Testing, o. E. Quelle: https://www.facebook.com/business/help/1738164643098669, Zugriffsdatum: 01.10.2025.

Meta Business Help Center (o. D.) (B), About Experiments, o. E. Quelle: https://www.facebook.com/business/help/1915029282150425, Zugriffsdatum: 01.10.2025.

Meta Business Help Center (o. D.) (C), About the Learning Phase, o. E. Quelle: https://www.facebook.com/business/help/112167992830700, Zugriffsdatum: 01.10.2025.

Meta Business Help Center (o. D.) (D), Significant Edits and the Learning Phase, o. E. Quelle: https://www.facebook.com/business/help/316478108955072, Zugriffsdatum: 01.10.2025.

Meta Business Help Center (o. D.) (E), Compare Attribution Settings in Meta Ads Reporting, o. E. Quelle: https://www.facebook.com/business/help/654970342692714, Zugriffsdatum: 01.10.2025.

Meta Business Help Center (o. D.) (F), About Overlapping Audiences, o. E. Quelle: https://www.facebook.com/business/help/1679591828938781, Zugriffsdatum: 01.10.2025.

Meta Business Help (o. D.) (H), About ad placements across Meta technologies, o. E. Quelle: https://www.facebook.com/business/help/407108559393196, Zugriffsdatum: 01.10.2025.

Meta Development Center (o. D.), Aggregated Event Measurement (AEM), o. E. Quelle: https://developers.facebook.com/docs/app-events/guides/aggregated-event-measurement/, Zugriffsdatum: 01.10.2025.

Micheli, M., Ponti, M., Craglia, M. und Berti Suman, A. (2020), Emerging models of Data governance in the age of datafication, in: *Big Data & Society*, 7(2), S. 1-15. https://doi.org/10.1177/2053951720948087

Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., Spitzer, E., Raji, I. D. und Gebru, T. (2019), Model Cards for Model Reporting, in: *FAT* '19*, New York: ACM, S. 220-229. https://doi.org/10.1145/3287560.3287596

Mohammed, S., Budach, L., Feuerpfeil, M., Ihde, N., Nathansen, A., Noack, N., Patzlaff, H., Naumann, F. und Harmouch, H. (2025), The effects of Data quality on machine learning performance on tabular data, in: *Information Systems*, 132, Art. 102549, S. 14-15. https://doi.org/10.1016/j.is.2025.102549

Moro, S., Cortez, P. und Rita, P. (2014), A data-driven approach to predict the success of bank telemarketing, in: *Decision Support Systems*, 62, S. 22-31. https://doi.org/10.1016/j.dss.2014.03.001

Mulier, L., Slabbinck, H. und Vermeir, I. (2021), This Way Up: The Effectiveness of Mobile Vertical Video Marketing, in: *Journal of Interactive Marketing*, 55, S. 1-15. https://doi.org/10.1016/j.intmar.2020.12.002

Mühlhoff, R. und Willem, C. A. (2023), Social Media Advertising for Clinical Studies: Ethical and Data Protection Implications of Online Targeting, in: *Big Data & Society*, January-June, S. 1-15. https://doi.org/10.1177/20539517231156127

Nguyen, D. Q.; Vu, T.; Nguyen, A. T. (2020): BERTweet: A pre-trained language model for English Tweets. In: Liu, Q.; Schlangen, D. (Hrsg.): Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations (EMNLP 2020). Online: *Association for Computational Linguistics*, S. 9–14. PDF: https://aclanthology.org/2020.emnlp-demos.2.pdf

Orazi, D. C. und Johnston, A. C. (2020), Running field experiments using Facebook split test, in: *Journal of Business Research*, 118, S. 189-198. https://doi.org/10.1016/j.jbusres.2020.06.053

OpenAI (2024), GPT-4o System Card, 08.08.2024, o. E. Quelle: https://cdn.openai.com/gpt-4o-system-card.pdf, Zugriffsdatum: 27.09.2025.

Papagiannidis, E., Enholm, I. M., Dremel, C., Mikalef, P. und Krogstie, J. (2023), Toward AI Governance: Identifying Best Practices and Potential Barriers and Outcomes, in: *Information Systems Frontiers*, 25, S. 123-141. https://doi.org/10.1007/s10796-022-10251-y

Pauwels, K., Ambler, T., Clark, B. H., LaPointe, P., Reibstein, D., Skiera, B., Wierenga, B. und Wiesel, T. (2009), Dashboards as a Service: Why, What, How, and What Research Is Needed?, in: *Journal of Service Research*, 12(2), S. 175-189. https://doi.org/10.1177/1094670509344213

Peters, K., Chen, Y., Kaplan, A. M., Ognibeni, B. & Pauwels, K. (2013): Social Media Metrics — A Framework and Guidelines for Managing Social Media. *Journal of Interactive Marketing*, 27(4), S. 281–298. https://doi.org/10.1016/j.intmar.2013.09.007

Pineau, J., Vincent-Lamarre, P., Sinha, K., Larivière, V., Beygelzimer, A., d'Alché-Buc, F., Fox, E. und Larochelle, H. (2021), Improving Reproducibility in Machine Learning Research (A Report from the NeurIPS 2019 Reproducibility Program), in: *Journal of Machine Learning Research*, 22, S. 1-20. Quelle: https://jmlr2020.csail.mit.edu/papers/volume22/20-303/20-303.pdf, Zugriffsdatum: 21.09.2025.

Pletikosa Cvijikj, I. und Michahelles, F. (2013), Online engagement factors on Facebook brand pages, in: *Social Network Analysis and Mining*, 3, S. 843-861. https://doi.org/10.1007/s13278-013-0098-8

Provost, F. und Fawcett, T. (2013), *Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking*, Sebastopol, CA: O'Reilly.

PwC Deutschland (2024), Künstliche Intelligenz im Arbeitsalltag. Ergebnisse einer Onlinepanelbefragung unter Berufstätigen in Deutschland, Juli 2024, o. E. https://www.pwc.de/de/mittelstand/pwc-umfrage-ki-im-arbeitsalltag.pdf?utm_source=chatgpt.com, Zugriffsdatum: 21.10.2025

Reinecke, S. und Klautzsch, E. (2013), Social Media Audit für Dienstleistungsunternehmen, in: Bruhn, M. und Hadwich, K. (Hrsg.), *Dienstleistungsmanagement und Social Media*, Wiesbaden: Springer Gabler, S. 108-123. https://doi.org/10.1007/978-3-658-01248-9_5

Reuter, C. und Kaufhold, M.-A. (2021), Soziale Medien in Notfällen, Krisen und Katastrophen, in: Reuter, C. (Hrsg.), *Sicherheitskritische Mensch-Computer-Interaktion, Wiesbaden*: Springer Vieweg, S. 407-430. https://doi.org/10.1007/978-3-658-32795-8_19.

Rodríguez-Ibáñez, M., Casañez-Ventura, A., Castejón-Mateos, F. und Cuenca-Jiménez, P.-M. (2023), A review on sentiment analysis from social media platforms, in: *Expert Systems with Applications*, 223, Art. 119862, S. 2-6. https://doi.org/10.1016/j.eswa.2023.119862

Rosário, A. T. und Dias, J. C. (2023), How has data-driven marketing evolved: Challenges and opportunities with emerging technologies, in: *International Journal of Information Management Data Insights*, 3(2), Art. 100203, S. 1-12. https://doi.org/10.1016/j.jjimei.2023.100203

Rostami, M., Bose, D., Narayanan, S. und Galstyan, A. (2023), Domain Adaptation for Sentiment Analysis Using Robust Internal Representations, in: *Findings of the Association for Computational Linguistics*: EMNLP 2023, S. 11484-11498. https://doi.org/10.18653/v1/2023.findings-emnlp.769

Roth, S., Beder, M. und Klicic, M. (2024), Leveraging GenAI for Brand Ecosystem Development: An Iterative Approach from Business Scenarios to Business Model and Marketing Strategy, in: Kabadayi, S., Bui, M. und Grewal, L. S. (Hrsg.), *2024 AMA Summer*

Academic Conference Proceedings, Vol. 35 - Reconnecting With Humanity: Marketing's Role in Promoting Responsible Technology While Serving People, Boston, MA: American Marketing Association, S. 507-530.

Röttger, P., Vidgen, B., Nguyen, D., Waseem, Z., Margetts, H. und Pierrehumbert, J. B. (2021), HateCheck: Functional Tests for Hate Speech Detection Models, in: *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*, S. 41-58. https://doi.org/10.18653/v1/2021.acl-long.4

Rust, R. T., Rand, W., Huang, M.-H., Stephen, A. T., Brooks, G. und Chabuk, T. (2021), EXPRESS: Real-Time Brand Reputation Tracking Using Social Media, in: *Journal of Marketing*, 85(4), S. 21-43. https://doi.org/10.1177/0022242921995173

Sia, N.-C., Hosseinian Far, A. & Toe, T. T. (2022): Challenges for the Adoption of Data Analytics Strategies by Small, Medium-Sized Enterprises in Singapore. In: Dadwal, S. S., Jahankhani, H. & Hassan, A. (Hrsg.): *Integrated Business Models in the Digital Age – Principles and Practices of Technology Empowered Strategies*. Cham: Palgrave Macmillan, S. 251–274. doi:10.1007/978-3-030-97877-8_7.

Schwaeke, J., Peters, A., Kanbach, D. K., Kraus, S. und Jones, P. (2024), The new normal: The status quo of AI adoption in SMEs, in: *Journal of Small Business Management*, S. 1297-1331. https://doi.org/10.1080/00472778.2024.2379999

Segijn, C. M., Kim, E. und van Ooijen, I. (2024): The Role of Perceived Surveillance and Privacy Cynicism in Effects of Multiple Synced Advertising Exposures on Brand Attitude. *Journal of Current Issues & Research in Advertising*, 45(4), S. 506–522. https://doi.org/10.1080/10641734.2024.2318711

Sheth, J. und Kellstadt, C. H. (2021), Next frontiers of research in Data driven marketing: Will techniques keep up with Data tsunami?, in: *Journal of Business Research*, 125, S. 780-784. https://doi.org/10.1016/j.jbusres.2020.04.050

Shumailov, I., Shumaylov, Z., Zhao, Y., Papernot, N., Anderson, R. und Gal, Y. (2024), AI models collapse when trained on recursively generated data, in: *Nature*, 631, S. 755-759. https://doi.org/10.1038/s41586-024-07566-y

Stieglitz, S., Mirbabaie, M., Ross, B. und Neuberger, C. (2018), Social media analytics - Challenges in topic discovery, Data collection, and Data preparation, in: *International Journal of Information Management*, 39, S. 156-168. https://doi.org/10.1016/j.ijinfomgt.2017.12.002

Teece, D. J., Pisano, G. und Shuen, A. (1997), Dynamic capabilities and strategic management, in: Strategic *Management Journal*, 18(7), S. 509-533. https://doi.org/10.1002/(SICI)1097-0266(199708)18:7%3C509::AID-SMJ882%3E3.0.CO;2-Z

Torre-Bastida, A. I., Gil, G., Minon, R. und Diaz-de-Arcaya, J. (2022), Technological Perspective of Data Governance in Data Space Ecosystems, in: Curry, E., Scerri, S. und Tuikka, T. (Hrsg.), *Data Spaces*, Cham: Springer, S. 65-87. Quelle: https://link.springer.com/chapter/10.1007/978-3-030-98636-0_4, Zugriffsdatum: 18.10.2025.

Unternehmerverband (2024), Vom angestellten Manager zum Unternehmer: Reiner Eckhardt über seinen Caramba-Management-buy-out, [uv]magazin 02/2024, o. S. Quelle: https://www.unternehmerverband.org/news/uv-magazin/24-2/caramba/, Zugriffsdatum: 02.09.2025.

Ur Rahaman, S. (2023), Real-Time Campaign Optimization: Using Analytics to Adapt Marketing Strategies on the Fly, in: *International Journal on Science and Technology*, 14(4), S. 4-8. https://doi.org/10.5281/zenodo.14471845

Urde, M., Greyser, S. A. und Balmer, J. M. T. (2007), Corporate brands with a heritage, in: *Journal of Brand Management*, 15(1), S. 4-19. https://doi.org/10.1057/palgrave.bm.2550106

Verma, S., Sharma, R., Deb, S. und Maitra, D. (2021), Artificial intelligence in marketing: Systematic review and future research direction, in: *International Journal of Information Management Data Insights*, 1(1), 100002, S. 2-3. https://doi.org/10.1016/j.jjimei.2020.100002

Vlačić, B., Corbo, L., Costa e Silva, S. und Dabic, M. (2021), The evolving role of artificial intelligence in marketing: A review and research agenda, in: *Journal of Business Research*, 128, S. 187-203. https://doi.org/10.1016/j.jbusres.2021.01.055

Wang, X., Wie, J., Schuurmans, D., Le, Q., Chi, E., Narang, S., Chowdhery, A. und Zhou, D (2023), Self-Consistency Improves Chain-of-Thought Reasoning in Language Models, in: *International Conference on Learning Representations*, S. 1-3. https://doi.org/10.48550/arXiv.2203.11171

Wang, S., Liu, Q., Ge, T., Lian, D. und Zhang, Z. (2021), A Hybrid Bandit Model with Visual Priors for Creative Ranking in Display Advertising, in: *Proceedings of The Web Conference 2021*, S. 2324-2334. https://doi.org/10.1145/3442381.3449910

Weber, M., Engert, M., Schaffer, N., Weking, J. und Krcmar, H. (2022), Organizational Capabilities for AI Implementation—Coping with Inscrutability and Data Dependency in AI, in: *Information Systems Frontiers*, 25(4), S. 1549-1569. https://doi.org/10.1007/s10796-022-10297-y

Wei, J., Wang, X., Schuurmans, D., Bosma, M., Ichter, B., Xia, F., Chi, E., Le, Q. und Zhou, D. (2022), Chain-of-Thought Prompting Elicits Reasoning in Large Language Models, in: *Advances in Neural Information Processing Systems*, 35, S. 2-4. https://doi.org/10.48550/arXiv.2201.11903

Westermann, A., Forthmann, J. und Kraemer, A. (2021), Social Listening: Game Changer im Reputationsmanagement, in: Terstiege, M. (Hrsg.), *KI in Marketing & Sales - Erfolgsmodelle aus Forschung und Praxis. Konzepte und Instrumente zum erfolgreichen Einsatz künstlicher Intelligenz*, Wiesbaden: Springer Fachmedien, S. 239-258.

WhatsApp Business (o. D.), Ads that click to WhatsApp, o. E.

Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K. und Cao, Y. (2022), ReAct: Synergizing Reasoning and Acting in Language Models, in: *Advances in Neural Information Processing Systems*, S. 1-3. https://doi.org/10.48550/arXiv.2210.03629

Yuan, S., Wang, J. und Zhao, X. (2013), Real-Time Bidding for Online Advertising: Measurement and Analysis, in: *Proceedings of ADKDD'13 (Workshop at KDD 2013)*, Chicago, IL, S. 1-8. https://doi.org/10.1145/2501040.2501980

Zwieglinska, Z. (2025), L'Oréal is putting AI at the center of its global marketing strategy, o. E. Quelle: https://www.glossy.co/beauty/loreal-is-putting-ai-at-the-center-of-its-global-marketing-strategy/, Zugriffsdatum: 24.10.2025.

Anhangverzeichnis

Anhang 1: Prompt-Dokumentation Creative-Erstellung 89

Anhang 2: Prompt-Dokumentation Text-Erstellung 90

Anhang 3: Social-Media-Audit Caramba 91

Anhang 4: Demografie Instagram - Caramba 91

Anhang 5: Human vs. KI Creative 92

Anhang 6: Prompt 1 92

Anhang 7: Prompt 2 93

Anhang 8: Prompt 3 93

Anhang 9: Prompt 4 94

Anhang 10: Prompt 5 94

Anhang 11: Prompt 6 95

Anhang 12: Prompt 7 95

Anhang 13: Prompt 8 96

Anhang 14: Prompt 9 96

Anhang 15: Prompt 10 97

Anhang 16: Prompt 11 97

Anhang 17: Prompt 12 98

Anhang 18: Prompt 13 98

Anhang 19: Prompt 14 99

Anhang 20: Prompt 15 99

Anhang 21: Werbeanzeigenerstellung KI 1 100

Anhang 22: Werbeanzeigenerstellung KI 2 100

Anhang 23: Werbeanzeigenerstellung KI 3 101

Anhang 24: Werbeanzeigenerstellung KI 4 101

Anhang 25: Werbeanzeigenerstellung KI 5 102

Anhang 26: Werbeanzeigenerstellung Human 1 102
Anhang 27: Werbeanzeigenerstellung Human 2 103
Anhang 28: Werbeanzeigenerstellung Human 3 103
Anhang 29: Werbeanzeigenerstellung Human 4 104
Anhang 30: Werbeanzeigenerstellung Human 5 104
Anhang 31: Werbeanzeigenerstellung Human 6 105
Anhang 32: Werbeanzeigenerstellung Human 7 105
Anhang 33: Werbeanzeigenerstellung Human 8 106
Anhang 34: Werbeanzeigenerstellung Human 9 106
Anhang 35: A/B-Test 2, Creative mit KI-Hinweis 107
Anhang 36: Ergebnisse der A/B-Tests. Oben: A/B-Test 1, unten A/B-Test 2 108
Anhang 37: Organigramm Cramaba GmbH, Quelle: Intern 109

Anhang

No.	GenAI	Prompt (Input)	Output
1.	Chat-GPT-5	Erstelle einen Prompt für Firefly 4 zur Bildgenerierung. Das Bild soll einen Motorradfahrer auf einem Motorrad zeigen, der das Caramba-Produkt „Magic Wonder“ in die Kamera hält.	**Motivbeschreibung** Fotorealistischer Shot eines Motorradfahrers auf einer kurvigen Landstraße in den Bergen, dynamische Bewegung, leichter Hintergrund-Motion-Blur. Der Fahrer sitzt auf einem modernen Naked Bike, trägt schwarze Lederjacke und Integralhelm (Visier unten, keine identifizierbaren Gesichter). In der rechten Hand hält er nah an die Kamera eine **Triggerflasche mit der Aufschrift „Magic Wonder“** (generisches Label, **ohne Markenlogo**), forciertes Perspektiv-Close-up: Produkt scharf, Hintergrund weich. Stimmung: Golden Hour, kontrastreiches, warmes Seitenlicht, knackige Reflexe auf der Flasche (frischer Glanz-Effekt). Bildsprache: Kampagnen-Look, clean, hochwertig, Social-Media-Ready. **Stil & Kamera** Content type: Photo, hyper-realistisch, detailreich, 35-mm-Look, geringe Tiefenschärfe (f/2.8),

			kurze Verschlusszeit (Action eingefroren), professionelle Studiobelichtung im Outdoor-Setup emuliert, fein dosierter Lens Flare. **Komposition** Produkt im Vordergrund im oberen Drittel, Rule of Thirds, Leading Lines der Straße auf das Bike, klare Trennung von Subjekt und Hintergrund. Negativ-Prompt keine Logos, keine Marken, kein Wasserzeichen, keine Text-Artefakte, keine zusätzlichen Flaschen oder Produkte, kein unscharfes Produkt, keine extremen Weitwinkel-Verzerrungen, keine übertriebenen HDR-Halos, keine Comic- oder Illustrationseffekte, kein Regen, kein Nebel, kein Schmutz auf der Flasche. Firefly-Einstellungen (empfohlen) **Modell:** *Firefly Image 4* (oder *Image 4 Ultra* für maximale Detailtreue). Adobe Hilfezentrum

			Content Type: *Photo* für realistische Ergebnisse. Photoshop Essentials **Aspect Ratio:** *Portrait (3:4)* und anschließend in Photoshop/Express auf **4:5** für Instagram zuschneiden (Firefly bietet 3:4/9:16, nicht nativ 4:5). Adobe Hilfezentrum+1 **Licht & Stil:** Warmes Golden-Hour-Licht, dezenter Lens Flare, geringe Tiefenschärfe; „Prompt Guidance/Enhance prompt“ optional nutzen, aber Kernbegriffe beibehalten. Adobe Hilfezentrum+1 Recht & Brand-Safety (wichtig) Firefly generiert **keine** Inhalte mit **Marken/Logos** - deshalb im Prompt **„generisches Label, ohne Markenlogo“** verwenden und bei Bedarf das echte Packshot-Label später per Compositing einsetzen. Adobe Hilfezentrum+2Adobe+2 Optional: Varianten-Snippets **Studio-Look:** „neutraler, dunkler Studio-Hintergrund, weiches

			3-Punkt-Licht, dezente Bodennebel-Textur, Bike nur angedeutet im Bokeh“. **Urban-Look:** „abendliche Stadtautobahn, Bokeh-Lichter, kühleres Color-Grading, metallische Reflexe, Produkt bleibt warm ausgeleuchtet“.
2.	Adobe Firefly	Siehe No 1. „Output“	

3.	Chat-GPT-5	Schreibe einen passenden Prompt für DALL-E.	Fotorealistisches Foto eines Motorradfahrers auf einer kurvigen Landstraße in den Bergen bei Golden Hour. Dynamische Szene mit leichtem Hintergrund-Motion-Blur. Moderner Naked-Bike-Style, Fahrer in schwarzer Lederjacke und Integralhelm (Visier unten, keine identifizierbaren Gesichter). Der Fahrer hält nah zur Kamera eine Sprühflasche mit der Aufschrift „Magic Wonder“ (generisches Produkt-Label, ohne Markenlogo), Produkt im Vordergrund knackscharf, Hintergrund weich (geringe Tiefenschärfe, ~f/2.8). Glanz-/Reflex-Highlights auf der Flasche (Frisch-gereinigt-Look), kontrastreiches Seitenlicht, dezenter Lens Flare. Komposition nach Rule of Thirds, Leading Lines der

			Straße auf Bike und Produkt. Hochwertiger Kampagnen-Look, clean, social-ready.
4.	Chat-GPT-5	Fotorealistisches Foto eines Motorradfahrers auf einer kurvigen Landstraße in den Bergen bei Golden Hour. Dynamische Szene mit leichtem Hintergrund-Motion-Blur. Moderner Naked Bike-Style, Fahrer in schwarzer Lederjacke und Integralhelm (Visier unten, keine identifizierbaren Gesichter). Der Fahrer hält nah zur Kamera eine Sprühflasche mit der Aufschrift „Magic Wonder“ (generisches Produkt-Label, ohne Markenlogo), Produkt im Vordergrund knackscharf, Hintergrund weich (geringe Tiefenschärfe, ~f/2.8). Glanz-/Reflex-Highlights auf der Flasche (Frisch-gereinigt-Look), kontrastreiches Seitenlicht, dezenter Lens Flare. Komposition nach Rule of Thirds, Leading Lines der Straße auf Bike und Produkt. Hochwertiger Kampagnen-Look, clean, social-ready. Integriere hierfür das Spruchmotiv und die Dose aus dem Anhang.	
5.	Chat-GPT-5	Füge das Caramba-Logo (anbei) in die linke obere Ecke ein und passe das Format auf 4:5 an. Achte darauf, dass du die Schrift der Originaldose (anbei) übernimmst.	Uff - ich konnte das Bild leider nicht generieren (es gab einen Fehler beim Erstellen/Rendern). Ich starte keinen neuen Versuch ohne dein Go.

			Wenn du möchtest, probiere ich es direkt nochmal mit exakt deinen Vorgaben: Caramba-Logo oben links eingeblendet Endformat 4:5 (z. B. 1024×1280) Dose/Etikett mit Original-Schriftbild gemäß beigefügtem Packshot Sag einfach „go“, dann setze ich’s sofort um.
6.	Chat-GPT-5	Go	

7.	Chat-GPT-5	Orientiere dich bei der Umsetzung an diesem Bild. Füge das Logo ein. Entferne im blauen Bereich der Dose die Schrift.	
8.	Chat-GPT-5	Achte darauf, dass die Optik der Dose erhalten bleibt. Entferne nur die Schrift im blauen Bereich. Orientiere dich weiterhin am ersten Bild und behalte den Sprühkopf der Dose bei.	

9.	Chat-GPT-5	Achte darauf, dass die Dose dem Original ähnlicher ist. Beachte die vorherigen Vorgaben.	
10.	Chat-GPT-5	Füge einen weißen Sprühkopf ein.	

11.	Chat-GPT-5	Ändere die Schrift in: Magic Wonder Sofort Glanz. Das Original findest du anbei.	
12.	Chat-GPT-5	Entferne die Schrift im markierten Bereich. Nehme keine weiteren Änderungen vor.	

13.	Chat-GPT-5	Füge im markierten Bereich die Originalschrift der Dose aus dem weißen Bereich ein. Die Dose findest du anbei. Der Schriftzug der Originaldose lautet: Magic Wonder Sofort Glanz	
14.	Chat-GPT-5	Entferne im markierten Bereich den Schriftzug. Nehme keine weiteren Änderungen vor.	

Anhang 1: Prompt-Dokumentation Creative-Erstellung

No.	GenAI	Prompt (Input)	Output
1.	ChatGPT-5	Rolle: Du bist Social-Media-	1. **Überschrift:** Sprühst du den Unterschied? **Primärtext:** Ein Wipe, viel Wow: Magic Wonder reinigt & poliert ohne Vorwäsche - perfekt

		Manager und erstellst eine Werbeanzeige für Instagram. Erstelle für die Werbeanzeige fünf Überschriften, Primärtexte und Beschreibungen. Ziel der Werbeanzeige ist die Steigerung der Awareness und Reichweite. Inhalt der Werbeanzeige ist die Bewerbung des Produktes „Magic Wonder“ von Caramba. Auf dem Anzeigenbild ist ein Motorradfahrer zu sehen, der das Produkt „Magic Wonder“ in die Kamera hält. Das Werbeanzeigen-Creative findest du anbei.	für Lack, Chrom & Kunststoff. Ideal nach der Tour. #TeamCaramba **Beschreibung:** Sofort-Glanz fürs Bike & Auto 2. **Überschrift:** Ride. Spray. Shine. **Primärtext:** Du kümmerst dich um die Kurven, Magic Wonder um den Glanz. In Minuten sauber, geschützt und ready für den nächsten Run. #TeamCaramba **Beschreibung:** Pflege to go - ohne Vorwäsche 3. **Überschrift:** Shortcut zu Showroom-Glanz **Primärtext:** Leichte Verschmutzungen weg, Finish on point - Carnaubawachs schützt den Lack über Wochen. Einfach aufsprühen, abwischen, glänzen. #TeamCaramba **Beschreibung:** Für Lack, Chrom & Kunststoff 4. **Überschrift:** Glanz, der mitfährt **Primärtext:** Insektenfilm? Straßenstaub? Weg. Magic Wonder poliert schonend und versiegelt - perfekt für Motorrad, Auto & Caravan. #TeamCaramba **Beschreibung:** Schnell sauber, lange geschützt 5. **Überschrift:** Sprühen statt schrubben **Primärtext:** Kein Eimer, kein Stress: 2-Step-Finish mit spürbarem Glanz - direkt von der Landstraße in deinen Feed. #TeamCaramba **Beschreibung:** Easy Pflege in Minuten

Anhang 2: Prompt-Dokumentation Text-Erstellung

Social Media Audit Caramba (https://www.instagram.com/carambachemie)
Stand: 28.09.2025

Betrachteter Kanal	Instagram
Resultate	**Publikationsmenge:** 80 Feed-Posts, 73 Reels. **Reichweite:** Feed gesamt 84 965 (Median/Beitrag 991; Ø 1 062); Reels gesamt 106 576 (Median/Beitrag 1 256; Ø 1 460). **Interaktionen:** Feed gesamt 3 182 (Median/Beitrag 37; Ø 39,8); Reels gesamt 3 992 (Median/Beitrag 44; Ø 54,7). Engagementrate (Interaktionen/Reichweite): Feed Median 3,84 % (Ø 3,92 %); Reels Median 3,34 % (Ø 3,83 %). **Formatvergleich:** Reels erzielen höhere Reichweite (+~37 % Ø vs. Feed) und mehr **Interaktionen pro Beitrag:** Feed-Posts liegen leicht vorn beim Median-Engagement. **Mess-Tools:** Meta Business Suite (Dashboard) und Metricool; KPIs: Follower, Reichweite, Impressionen, Interaktionen.
Online Nutz-und Kaufverhalten	**Zielgruppe:** Überwiegend 18–34 Jahre, ca. 60 % männlich (Metricool). **Tracking-Lücke:** Keine belastbaren Daten zu Website-Besuchen oder Käufen aus Instagram (fehlende UTM-/Conversion-Messung). **Commerce-Nutzung:** Shopping-Features/Link-Routen nur eingeschränkt eingesetzt; Potenzial für Produktmarkierungen, Shop-Tabs und klare CTAs.
Strategie und Ziele	**Ziele vorhanden, aber nicht operationalisiert:** Markenbekanntheit und Community-Aufbau sind definiert, jedoch ohne konkrete Soll-KPIs. **Dokumentation:** Redaktionsplan **Format-Performance ungenutzt:** Reels liefern überdurchschnittliche Reichweite, Karussells tendenziell mehr Engagement – diese Stärken werden bislang nicht systematisch in der Planung berücksichtigt. **Handlungsbedarf:** Ziele in SMARTe KPIs übersetzen, Redaktionsplan und Verantwortlichkeiten festschreiben, Formatrollen definieren (z. B. Reels = Reichweite, Karussell = Interaktion) und regelmäßige Review-Zyklen etablieren.
Kunden-Organisation Prozesse Reinecke, S., Klautzsch, E. (2013). Social Media-Audit für Dienstleistungsunternehmen. In: Bruhn, M., Hadwich, K. (eds) Dienstleistungsmanagement und Social Media. Springer Gabler, Wiesbaden. https://doi.org/10.1007/978-3-658-01248-9_5, S. 108 - 123 In Anlehnung an: Reinecke, S., Klautzsch, E. (2013), S. 123.	**Ressourcen & Rollen:** Betreuung liegt bei einer Person (Social Media Manager) **Prozessreife: Keine** dokumentierten Prozesse für Planung, Veröffentlichung, Community-Management oder Krisenkommunikation. **Richtlinien & Governance: Fehlende** Social-Media-Guidelines (Tonalität, Response-Standards, Do/Don't, Eskalationspfade); erhöhtes **Reputations- und Compliance-Risiko**. **Monitoring & Eskalation: Kein** festgelegtes **Eskalationsschema** für kritische Kommentare/Anfragen; geringe Reaktionssicherheit in Peaks oder Krisen. **Tool-Nutzung:** Dashboard vorhanden (Meta Business Suite), aber **ohne** verbindliche Workflows/Checklisten zur Qualitätssicherung.

Anhang 3: Social-Media-Audit Caramba

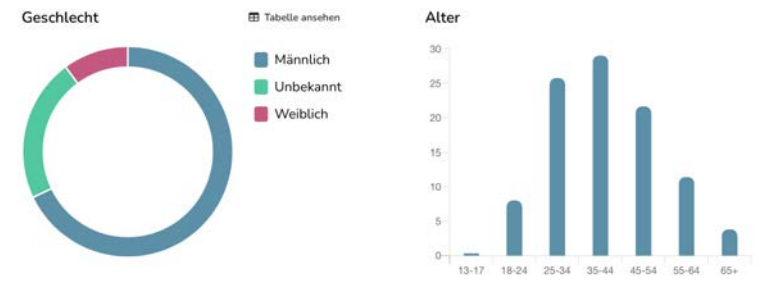

Quelle: Metricool.com, Caramba Instagram Account

Anhang 4: Demografie Instagram - Caramba

ID: 2025-1

Bearbeitung mit Canva:

- Zuschnitt auf das Format 4:5 an.
- Einfügen des Marken-Logos und Spruch „Sprühst du den Unterschied?“

SPRÜHST
DU DEN
UNTERSCHIED?

caramba

Erstellung mit Adobe Firefly:

- Firefly Image 4 Text-zu-Bild
- Format 4:5.
- Referenzen: Magic Wonder Dose (Komposition) und Motorradfahrer mit Magic Wonder Dose (Stil)
- Farbe: Gedeckt Farben
- Beleuchtung: Gedämpftes Licht
- Kameraperspektive: Weitwinkel

Anhang 5: Human vs. KI Creative

Adobe Firefly vs DALL-E
Adobe Firefly, prompt Generierung mit ChatGPT

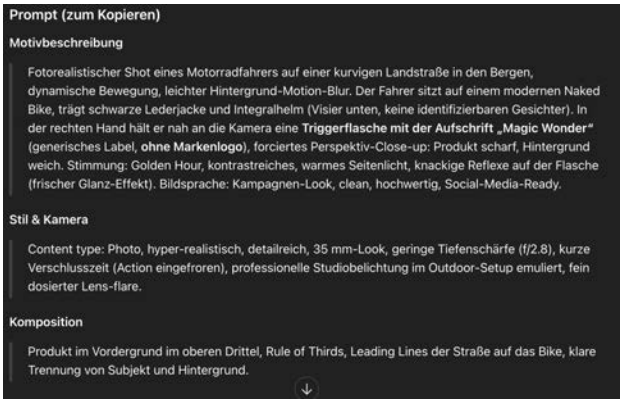

Anhang 6: Prompt 1

Adobe Firefly vs DALL-E
Adobe Firefly Bildgenerierung

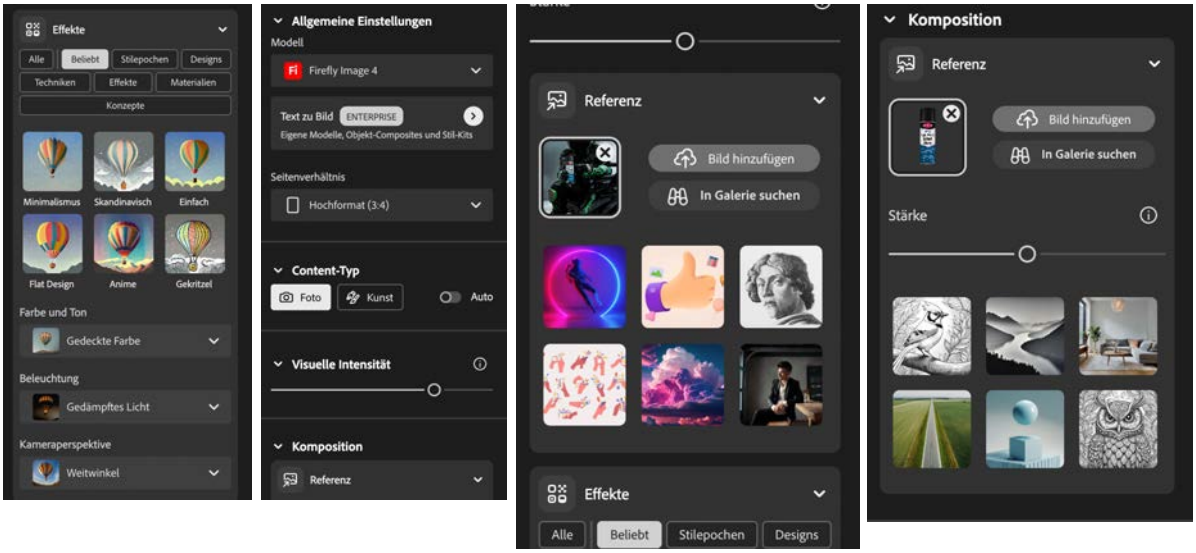

Anhang 7: Prompt 2

Adobe Firefly vs DALL-E
Adobe Firefly Bildgenerierung

Anhang 8: Prompt 3

Adobe Firefly vs DALL-E
DALL-E, Prompt-Adaption Adobe Firefly

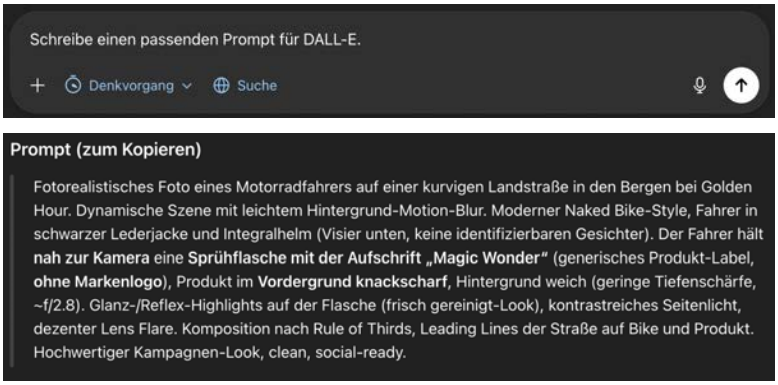

Anhang 9: Prompt 4

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

Anhang 10: Prompt 5

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

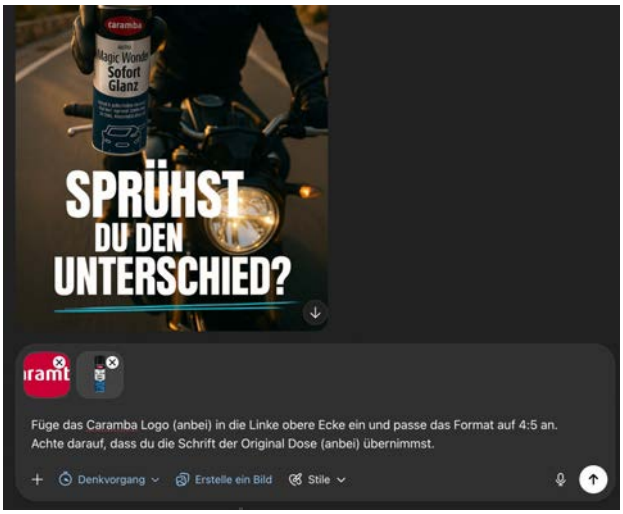

Anhang 11: Prompt 6

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

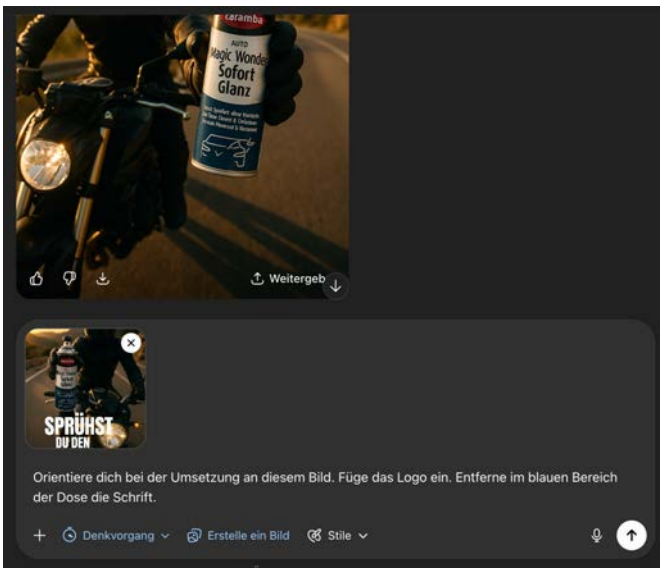

Anhang 12: Prompt 7

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

Anhang 13: Prompt 8

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

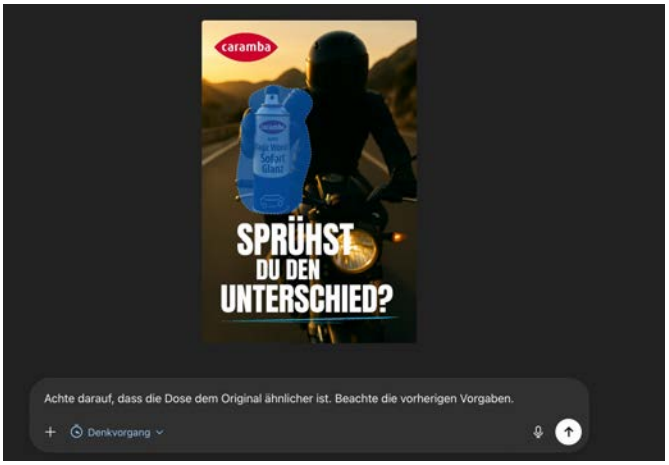

Anhang 14: Prompt 9

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

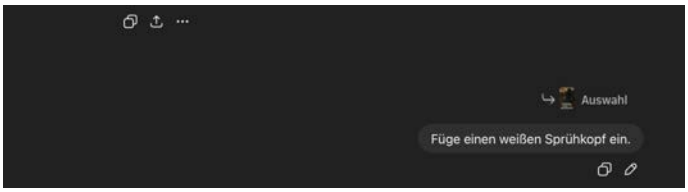

Anhang 15: Prompt 10

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

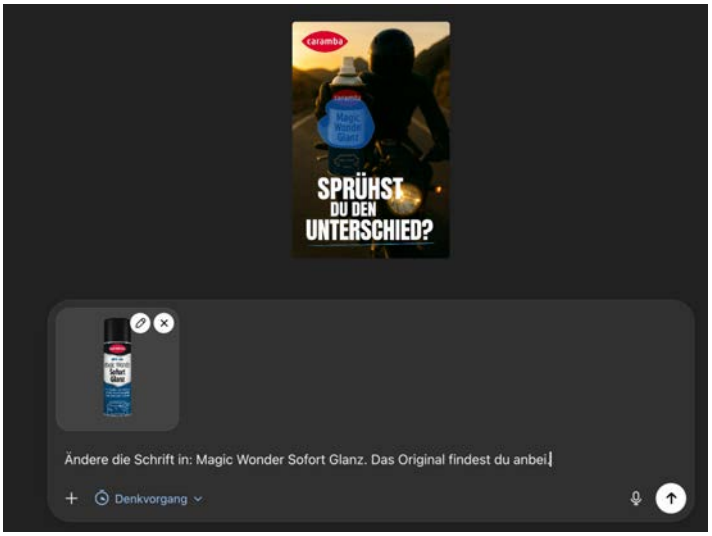

Anhang 16: Prompt 11

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

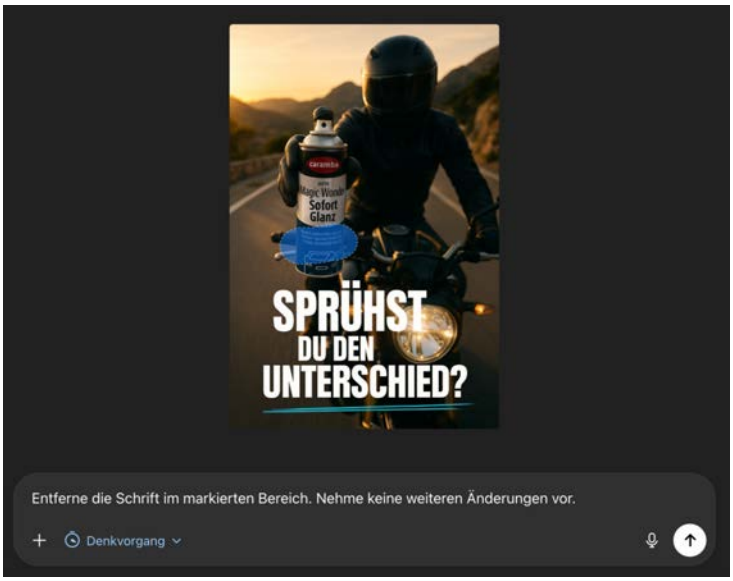

Anhang 17: Prompt 12

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

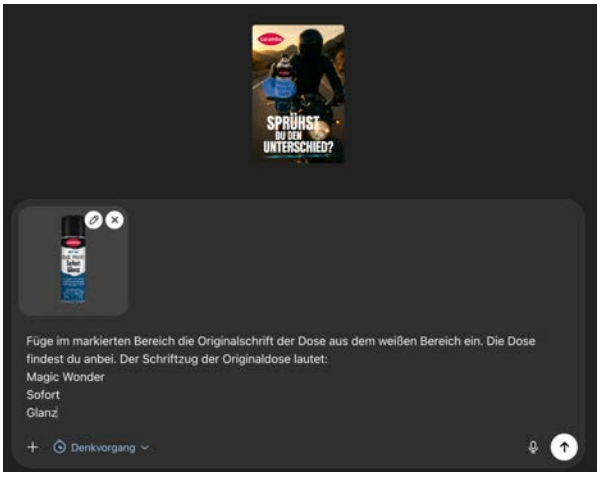

Anhang 18: Prompt 13

Adobe Firefly vs DALL-E
DALL-E Bildgenerierung

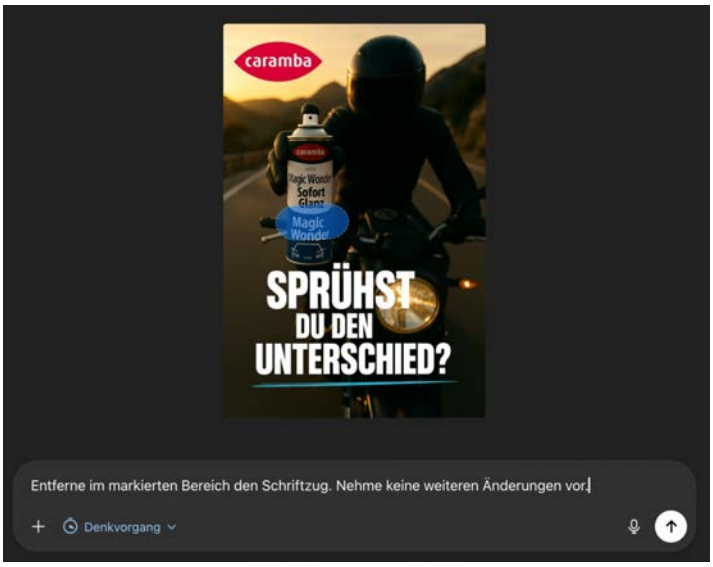

ID: 2025-2

Anhang 19: Prompt 14

ChatGPT Textgenerierung

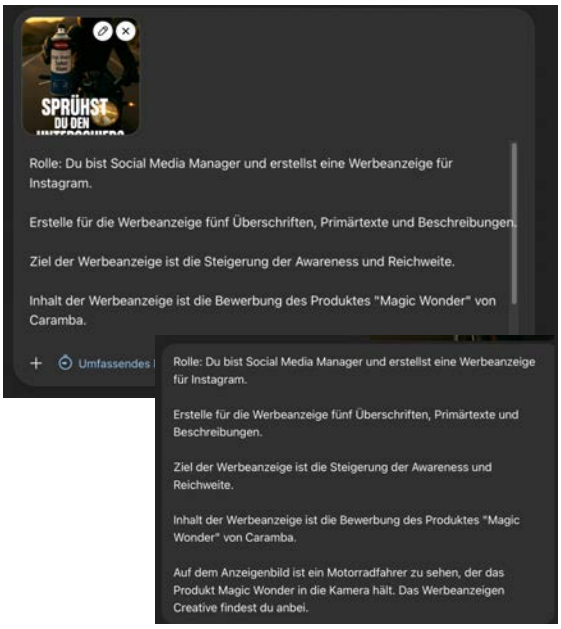

Überschrift: Sprühst du den Unterschied?
Primärtext: Ein Wipe, viel Wow: Magic Wonder reinigt & poliert ohne Vorwäsche – perfekt für Lack, Chrom & Kunststoff. Ideal nach der Tour. #TeamCaramba
Beschreibung: Sofort-Glanz fürs Bike & Auto

2.Überschrift: Ride. Spray. Shine.
Primärtext: Du kümmerst dich um die Kurven, Magic Wonder um den Glanz. In Minuten sauber, 3.geschützt und ready für den nächsten Run. #TeamCaramba
Beschreibung: Pflege to go – ohne Vorwäsche

3.Überschrift: Shortcut zu Showroom-Glanz
Primärtext: Leichte Verschmutzungen weg, Finish on point – Carnaubawachs schützt den Lack über Wochen.
Einfach aufsprühen, abwischen, glänzen. #TeamCaramba
Beschreibung: Für Lack, Chrom & Kunststoff

4.Überschrift: Glanz, der mitfährt
Primärtext: Insektenfilm? Straßenstaub? Weg. Magic Wonder poliert schonend und versiegelt – perfekt für Motorrad, Auto & Caravan. #TeamCaramba
Beschreibung: Schnell sauber, lange geschützt

5.Überschrift: Sprühen statt schrubben
Primärtext: Kein Eimer, kein Stress: 2-Step-Finish mit spürbarem Glanz – direkt von der Landstraße in deinen Feed. #TeamCaramba
Beschreibung: Easy Pflege in Minuten

Anhang 20: Prompt 15

Einrichtung der Kampagne A/B Test: KI

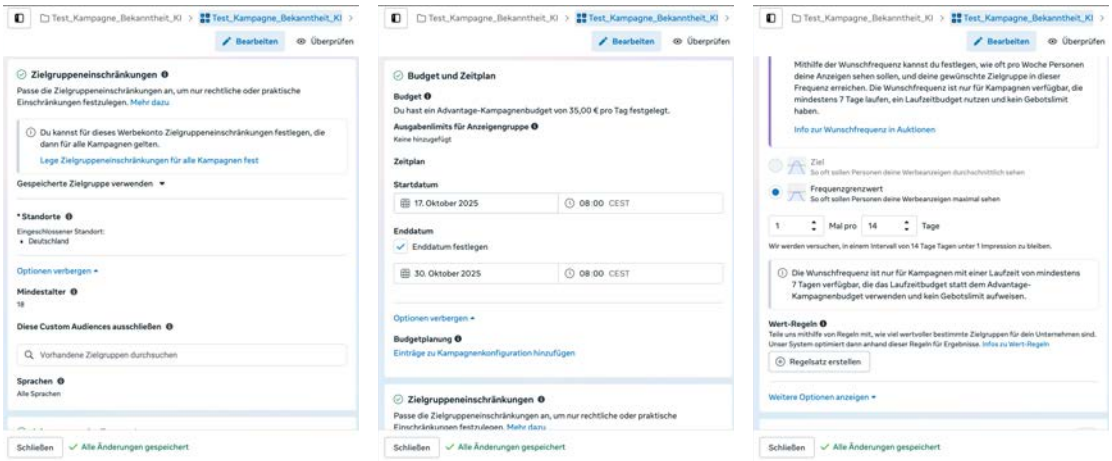

Anhang 21: Werbeanzeigenerstellung KI 1

Einrichtung der Kampagne A/B Test: KI

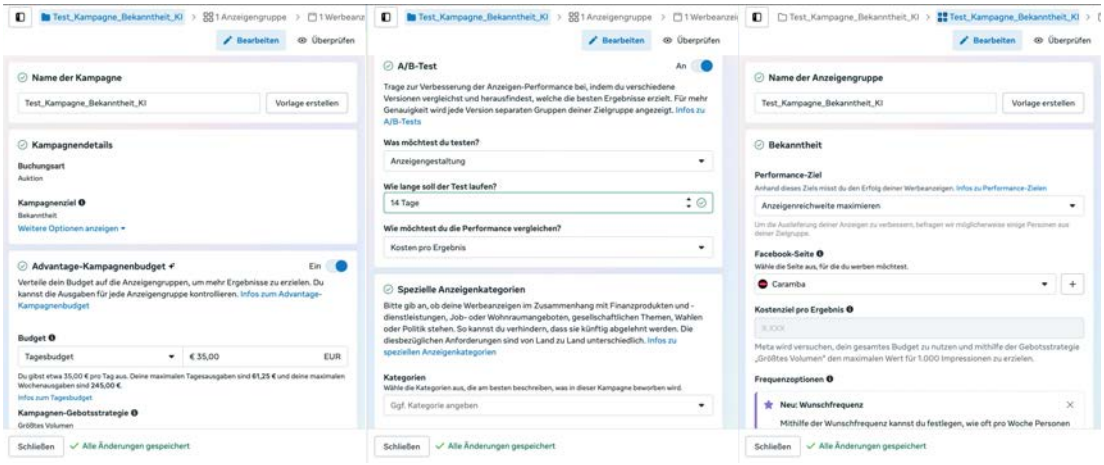

Anhang 22: Werbeanzeigenerstellung KI 2

Einrichtung der Kampagne A/B Test: KI

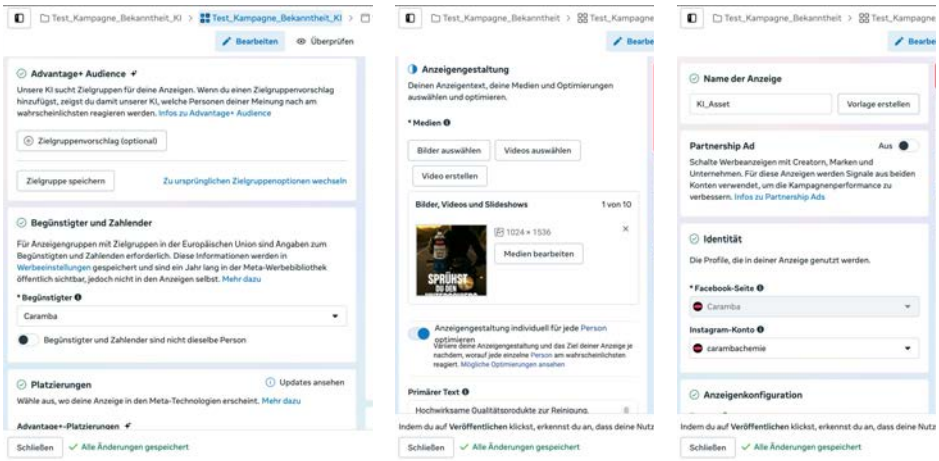

Anhang 23: Werbeanzeigenerstellung KI 3

Einrichtung der Kampagne A/B Test: KI

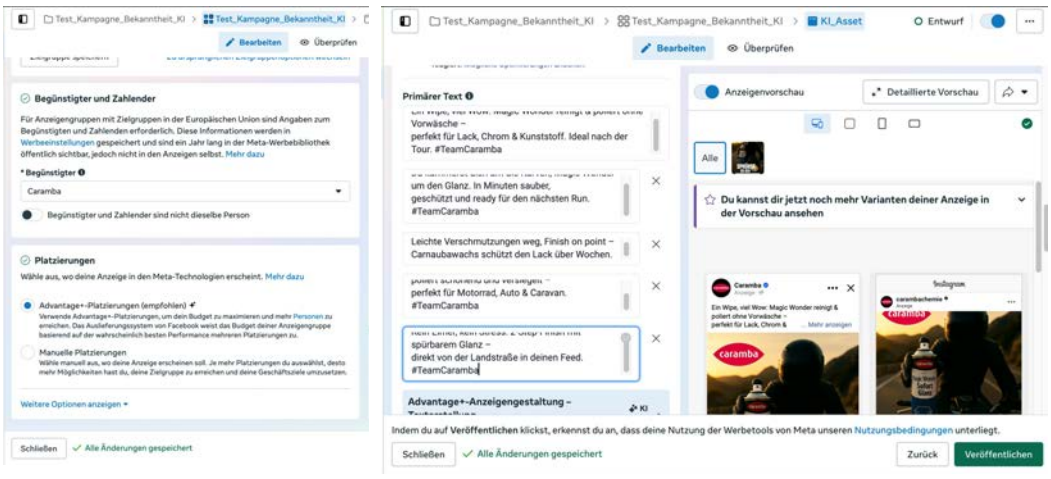

Anhang 24: Werbeanzeigenerstellung KI 4

Einrichtung der Kampagne A/B Test: KI

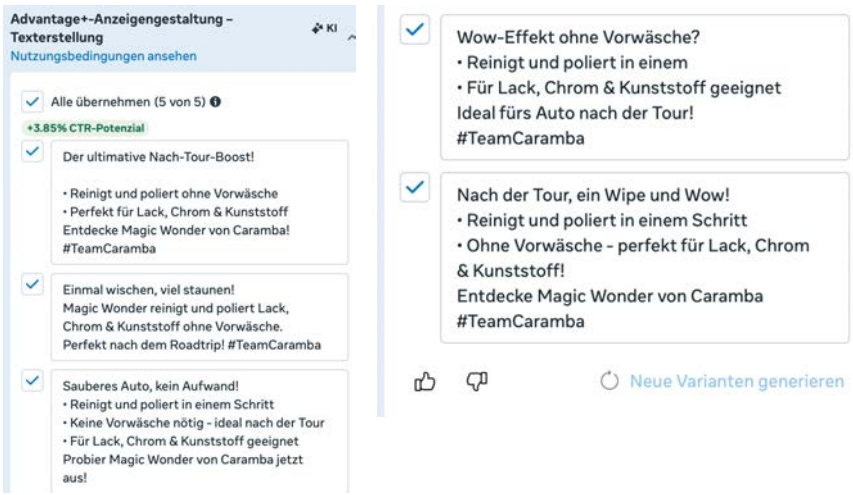

Anhang 25: Werbeanzeigenerstellung KI 5

Einrichtung der Kampagne A/B Test: Human

Überschrift: Golden Hour, echter Glanz
Primärtext: Du nimmst die Kurven. Magic Wonder macht das Finish. Kurz aufsprühen, abwischen, weiterfahren. Ohne Vorwäsche, sauberer Look für Lack, Chrom & Kunststoff.
Beschreibung: Sofort-Glanz in zwei Moves
2.Überschrift: Ein Tuch. Ein Spray. Wow.
Primärtext: Nach der Tour einmal drüber: Insektenfilm weg, Teerspuren weg, Glanz bleibt. Hält locker über Wochen und dein Feed dankt's dir.
Beschreibung: Reinigt, poliert, schützt
3.Überschrift: Ride, wipe, shine.
Primärtext: Kein Eimer, kein Drama. Magic Wonder macht Bike & Auto in Minuten ready, deal für unterwegs und den nächsten Shot.
Beschreibung: Glanz ohne Vorwäsche
4.Überschrift: Wenn's schnell gut aussehen soll
Primärtext: Staub drauf? Spray drauf. Mit Mikrofasertuch abwischen – fertig. Draußen auf Lack/Chrom & im Innenraum auf glatten Kunststoffflächen einsetzbar.
Beschreibung: Sauber & smooth, überall.
5.Überschrift: Glanz, der mitreist
Primärtext: Aussichtspunkt, kurzer Stopp, ein Sprühstoß: Der Tank glänzt wieder und die Schutzschicht hält richtig lange.
Beschreibung: Langanhaltendes Finish to go

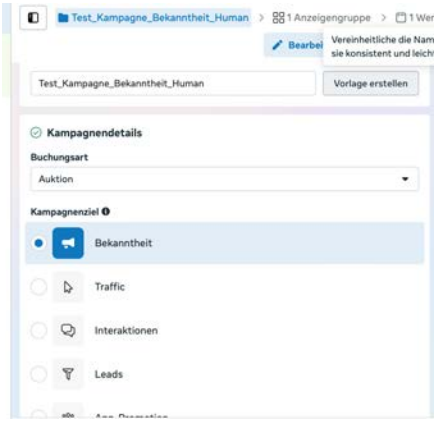

Anhang 26: Werbeanzeigenerstellung Human 1

Einrichtung der Kampagne A/B Test: Human

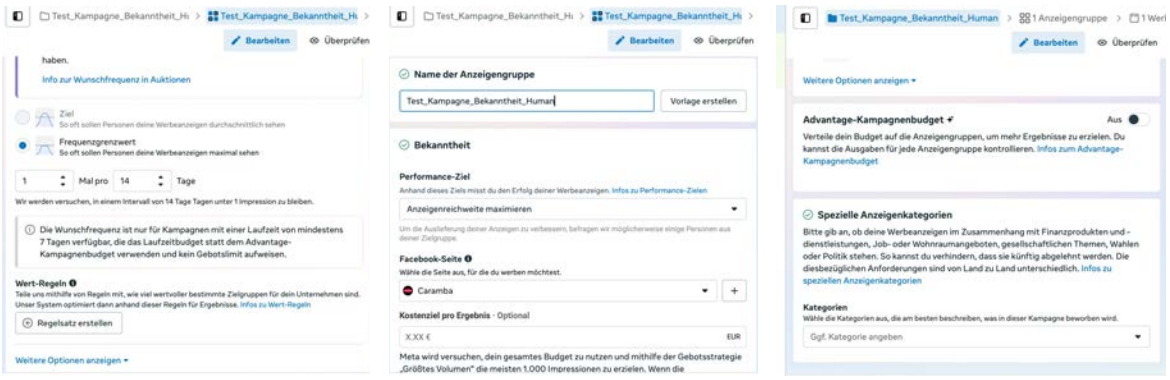

Anhang 27: Werbeanzeigenerstellung Human 2

Einrichtung der Kampagne A/B Test: Human

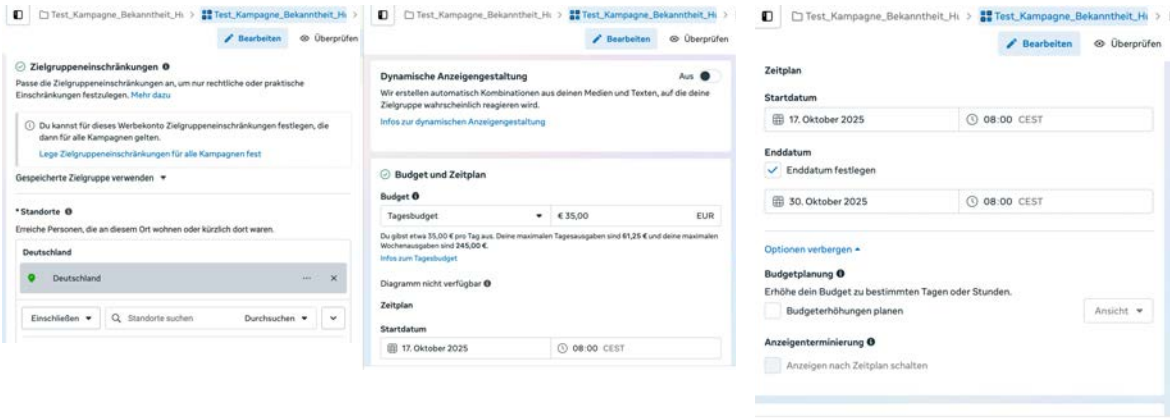

Anhang 28: Werbeanzeigenerstellung Human 3

Einrichtung der Kampagne A/B Test: Human

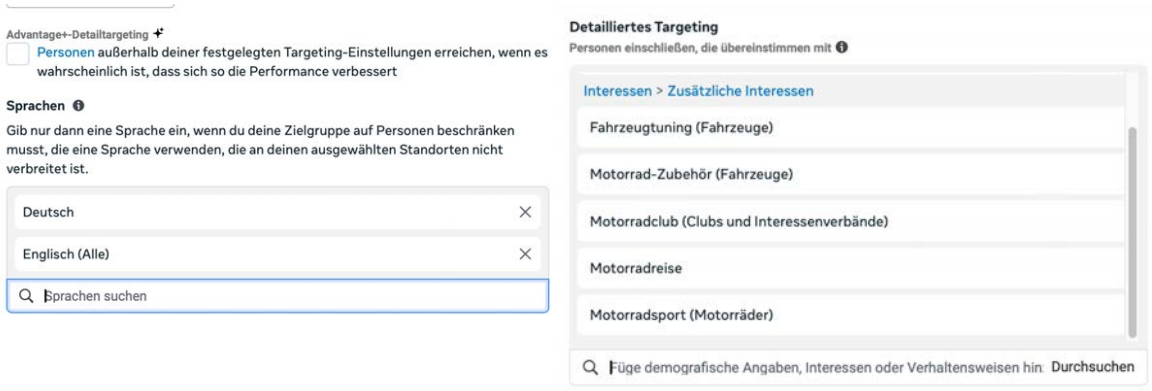

Anhang 29: Werbeanzeigenerstellung Human 4

Einrichtung der Kampagne A/B Test: Human

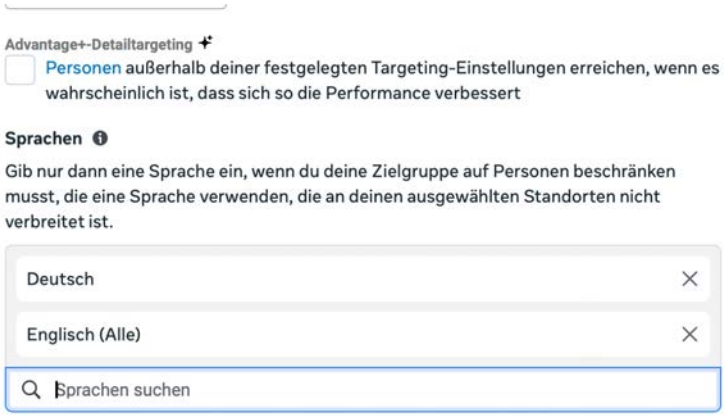

Anhang 30: Werbeanzeigenerstellung Human 5

Einrichtung der Kampagne A/B Test: Human

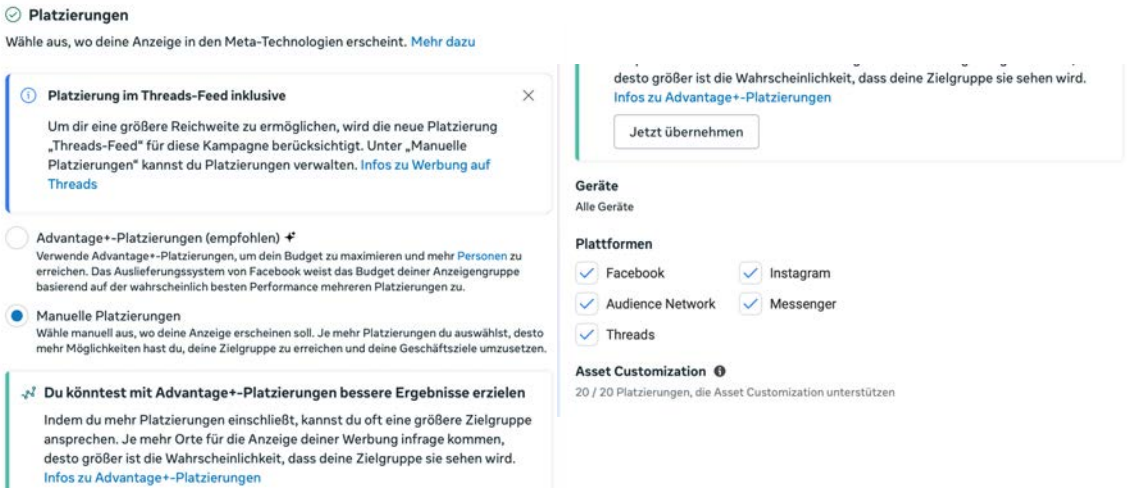

Anhang 31: Werbeanzeigenerstellung Human 6

Einrichtung der Kampagne A/B Test: Human

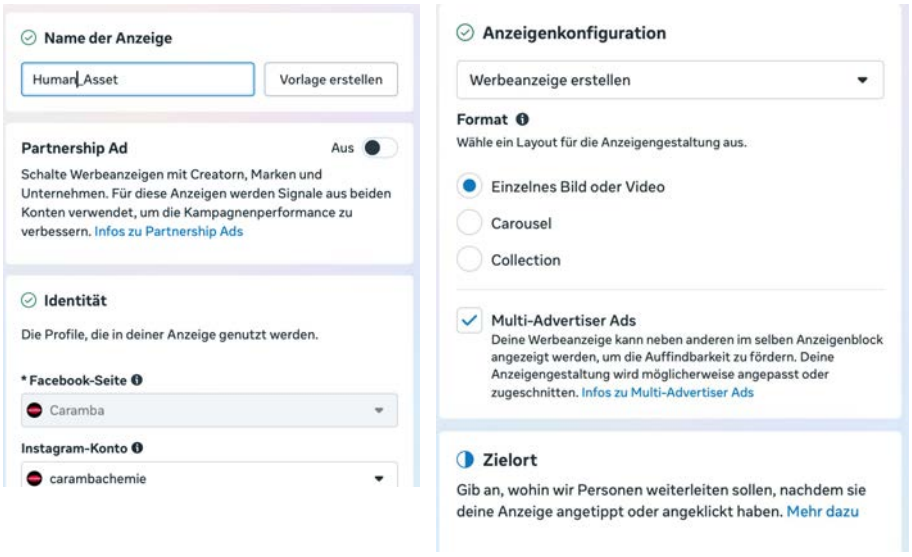

Anhang 32: Werbeanzeigenerstellung Human 7

Einrichtung der Kampagne A/B Test: Human

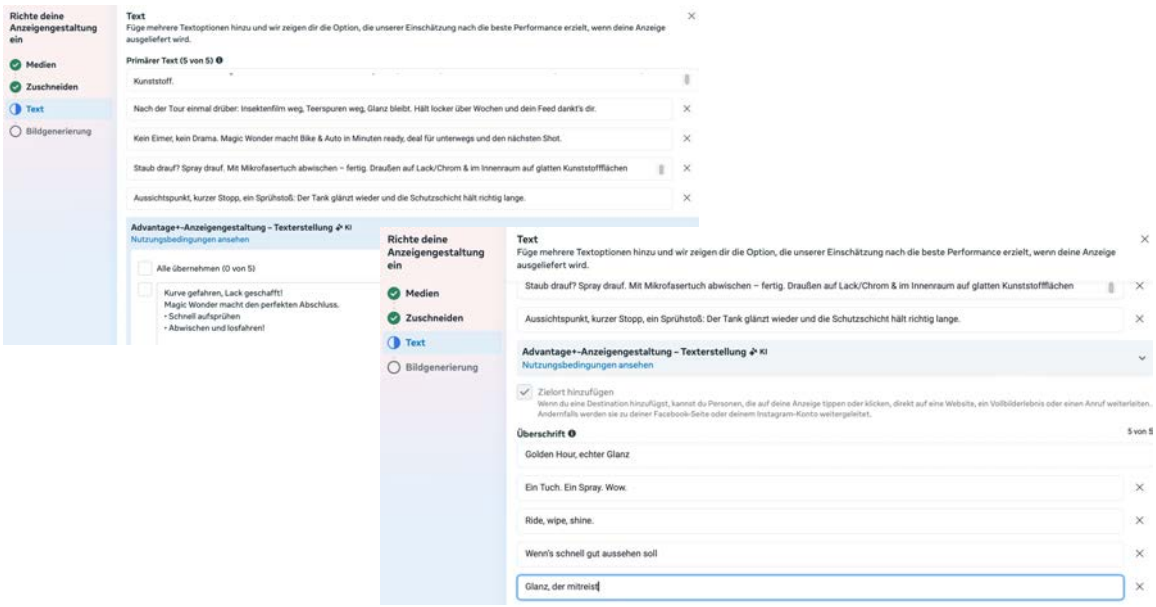

Anhang 33: Werbeanzeigenerstellung Human 8

Einrichtung der Kampagne A/B Test: Human

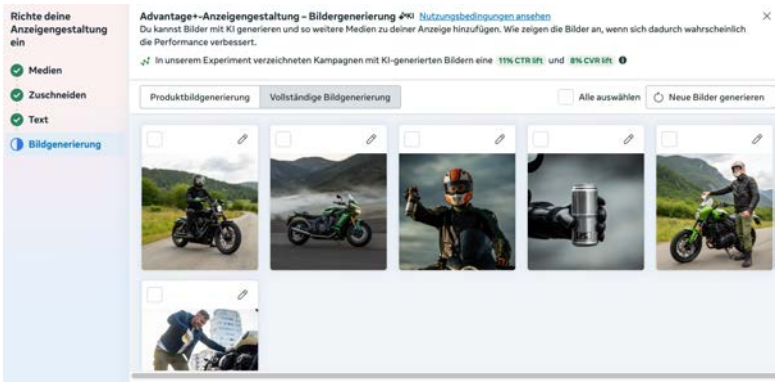

Anhang 34: Werbeanzeigenerstellung Human 9

A/B Test II: Test entspricht der gleichen Vorgehensweise, wie auf den Folien 4-33 beschrieben. KI generierter Asset wurde Ausgetauscht mit dem Verweis „KI-Generiertes Bild“. Werbeanzeigenkonfiguration identisch, Text wurde ergänzt durch “Mit KI generiert.“.

ID: 2025-1

ID: 2025-2b

Anhang 35: A/B-Test 2, Creative mit KI-Hinweis

A/B-Test 1

Berichtsstart	Berichtsende	Name der Anzeigengruppe	Creative ID
2025-09-25	2025-10-24	Test_Kampagne_Bekanntheit_KI	2025-2
2025-09-25	2025-10-24	Test_Kampagne_Bekanntheit_Human	2025-1

A/B-Test 2

Berichtsstart	Berichtsende	Name der Anzeigengruppe	Creative ID
2025-09-26	2025-10-25	Test_Kampagne_Bekanntheit_Human	2025-1
2025-09-26	2025-10-25	Test_Kampagne_Bekanntheit_KI_Hinwei	2025-2b

Auslieferung der Anzeigengruppe	Art des Gebots	Anzeigengruppenbudget
recently_completed	ABSOLUTE_OCPM	250
recently_completed	ABSOLUTE_OCPM	250

Auslieferung der Anzeigengruppe	Art des Gebots	Anzeigengruppenbudget
recently_completed	ABSOLUTE_OCPM	250
recently_completed	ABSOLUTE_OCPM	250

Attributionseinstellung	Ergebnisse	Reichweite	Impressionen
7 Tage (Klick) oder 1 Tag (Aufru	163322	163322	168938
7 Tage (Klick) oder 1 Tag (Aufru	163417	163417	163785

Attributionseinstellung	Ergebnisse	Reichweite	Impressionen
7 Tage (Klick) oder 1 Tag (Aufru	144866	144866	147036
7 Tage (Klick) oder 1 Tag (Aufru	158412	158412	160376

Kosten pro Ergebnis	Ausgegebener Betrag (EUR)	OEC	Frequenz
1,49918566	244,85	667,0288	1,034386
1,49892606	244,95	667,1443	1,002252

Kosten pro Ergebnis	Ausgegebener Betrag (EUR)	OEC	Frequenz
1,68956139	244,76	591,8696	1,014979
1,54647375	244,98	646,6324	1,012398

CPM (Kosten pro 1.000 Impressionen) (EUR)	Beitragsinteraktionen
1,449348	172
1,495558	166

CPM (Kosten pro 1.000 Impressionen) (EUR)	Beitragsinteraktionen
1,664626	177
1,527535	166

Anhang 36: Ergebnisse der A/B-Tests. Oben: A/B-Test 1, unten A/B-Test 2

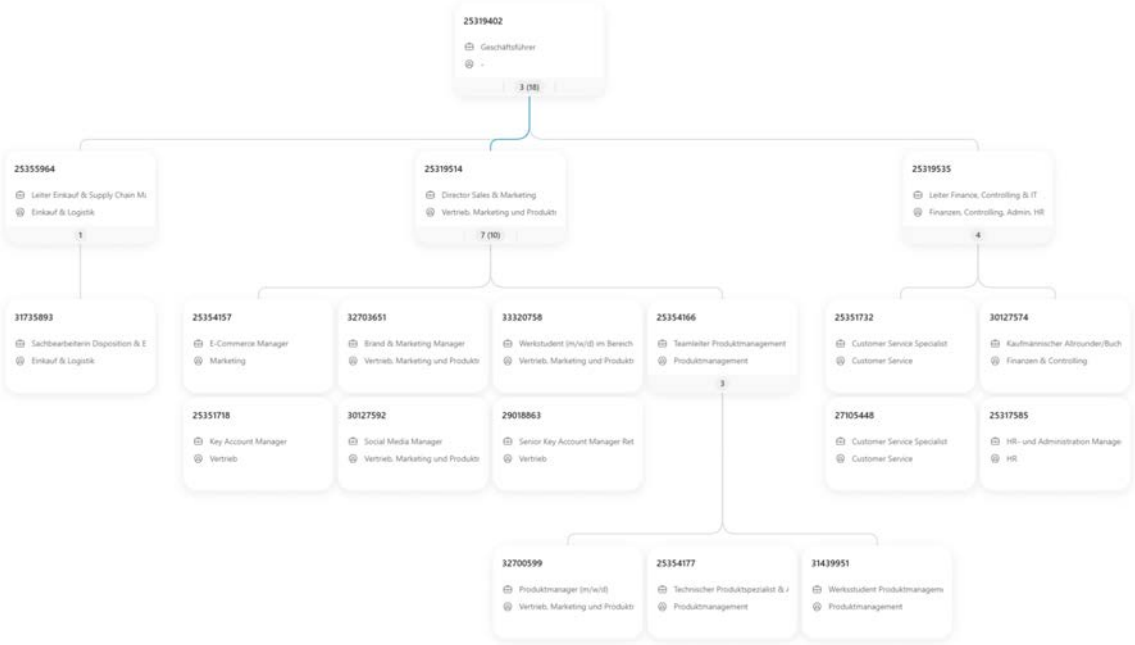

Anhang 37: Organigramm Cramaba GmbH, Quelle: Intern

Eidesstattliche Erklärung bei Nutzung von generativer KI

Ich versichere an Eides statt durch meine Unterschrift, dass ich die vorliegende Arbeit selbständig und nur unter Angabe der genutzten Hilfsmittel angefertigt und alle Stellen, die ich wörtlich oder annähernd wörtlich aus Veröffentlichungen entnommen habe, als solche kenntlich gemacht habe, mich auch keiner anderen als der angegebenen Literatur oder sonstiger Hilfsmittel bedient habe. Zusätzlich versichere ich, dass ich beim Einsatz von generativen IT- bzw. KI-Werkzeugen und/oder KI-gestützten Schreibwerkzeugen diese als Liste mit ihrem Produktnamen, Angaben zu genutzten Funktionen der Software und zum Nutzungsumfang vollständig aufgeführt habe. Wörtliche sowie paraphrasierende Übernahmen aus Ergebnissen dieser Werkzeuge habe ich analog zu anderen Quellenangaben gekennzeichnet.

Des Weiteren hat die Arbeit in dieser oder ähnlicher Form noch keiner anderen Prüfungsbehörde vorgelegen.

Essen, 15.11.2025

Klostermeyer, Kevin