

Welche Auswirkungen hat die Nutzung von KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Kaufverhalten der Konsument:innen?

Masterarbeit

am

Fachhochschul-Masterstudiengang
Betriebswirtschaft & Wirtschaftspsychologie
an der Ferdinand Porsche FERNFH

Sophie Steurer

51906750

Begutachter*in: Mag.a Dr.in Agnieszka Zablocki

Wien, Mai 2025

Eidesstattliche Erklärung

Ich erkläre hiermit, dass ich die vorliegende Arbeit selbstständig und ohne Benutzung anderer als der angegebenen Quellen und Hilfsmittel angefertigt habe. Alle Stellen, die wörtlich oder sinngemäß übernommen wurden, habe ich als solche kenntlich gemacht. Die Arbeit wurde in gleicher oder ähnlicher Form noch keiner anderen Prüfungsbehörde vorgelegt oder veröffentlicht. Die vorliegende Fassung entspricht der eingereichten elektronischen Version. Ich bestätige zudem, dass ich den Datenschutz einhalte und etwaiges Datenmaterial, das ich im Zuge meiner Masterarbeit gesammelt habe, nach Abschluss meines Studiums unwiderruflich von meinem Datenspeicher lösche.

Mai 2025

A handwritten signature in black ink, reading "Sophie Feuer". The script is cursive and fluid, with the first name "Sophie" and the last name "Feuer" clearly distinguishable.

Zusammenfassung

Angesichts der zunehmenden Relevanz von künstlicher Intelligenz (KI) im digitalen Marketing widmet sich diese Arbeit der Untersuchung der Wirkung KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Konsumverhalten. Ausgangspunkt bildet die Forschungsfrage: „Welche Auswirkungen hat die Nutzung von KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Kaufverhalten der Konsument:innen?“. Zur Beantwortung wurde eine quantitative Online-Befragung durchgeführt, in der sowohl personalisierte als auch nicht-personalisierte Werbeeinhalte getestet wurden. Die Wirkung wurde entlang zentraler Dimensionen wie Kaufabsicht, Werbewahrnehmung und Datenschutzbedenken analysiert. Die Ergebnisse zeigen, dass KI-gestützte Personalisierung nicht pauschal zu einer höheren Kaufabsicht führt, jedoch insbesondere bei Nutzer:innen mit geringer Datenschutzsensibilität positiv bewertet wird. Gleichzeitig verdeutlichen die Daten, dass ein erhöhtes Bewusstsein für Privatsphäre die Werbewirkung signifikant mindern kann. Damit leistet die Arbeit einen Beitrag zur differenzierten Betrachtung der Effektivität personalisierter Online-Werbung und unterstreicht die Bedeutung einer ethisch reflektierten Anwendung von KI im Marketing.

Schlüsselbegriffe: Künstliche Intelligenz (KI), Personalisierung, Online-Werbung, Kaufverhalten, Datenschutz, Werbewirkung

Abstract

Given the increasing relevance of artificial intelligence (AI) in digital marketing, this thesis investigates the impact of AI-driven personalization in online advertising on consumer behavior. The central research question is: “What effects does the use of AI-based personalization in online advertisements have on consumer purchasing behavior?” To explore this, a quantitative online survey was conducted in which both personalized and non-personalized advertisements were tested. The effects were analyzed across key dimensions such as purchase intention, advertising perception, and privacy concerns. The results indicate that AI-powered personalization does not universally lead to higher purchase intentions, but is rated more positively by users with lower privacy sensitivity. At the same time, the data show that greater privacy awareness can significantly reduce advertising effectiveness. Thus, this thesis contributes to a differentiated understanding of personalized online advertising and highlights the importance of ethically responsible AI applications in marketing.

Keywords: Artificial Intelligence (AI), Personalization, Online Advertising, Consumer Behavior, Data Privacy, Advertising Effectiveness

Inhaltsverzeichnis

1	Einleitung.....	1
1.1	Problemstellung.....	1
1.2	Forschungsfrage und Ziel der Arbeit.....	3
1.3	Aufbau der Arbeit	4
2	Theoretische Grundlagen	5
2.1	Marketing	5
2.1.1	Digitalisierung und Wandel im Marketing	6
2.1.2	Bedeutung von Online-Werbung im heutigen Marketing-Mix.....	7
2.1.3	Online-Werbeanzeigen & Personalisierung.....	8
2.2	Theoretische Modelle zur Erklärung von Konsumentenverhalten und Kaufabsichten.....	9
2.2.1	Theory of Planned Behaviour (TPB).....	10
2.2.2	Elaboration Likelihood Model (ELM).....	11
2.2.3	Technology Acceptance Model (TAM)	13
2.2.4	Attitude Toward the Ad (ATTA)	15
2.2.5	Purchase Intention (PI)	16
2.2.6	Zusammenfassung der Modelle	18
2.3	Künstliche Intelligenz.....	19
2.3.1	Maschinelles Lernen	20
2.3.2	Big Data und Analytics	22
3	KI-gestützter Personalisierung in Online-Werbeanzeigen.....	26
3.1	Personalisierung von Inhalten durch KI	26
3.2	Personalisierte Onlinewerbeschlaltungen durch KI.....	28
3.3	KI in der Marketingforschung.....	28
3.4	Einsatz von KI im Marketing und Datenschutz.....	31
4	Empirische Untersuchung	34
4.1	Forschungsfrage und Hypothese.....	34

4.2	Quantitative Forschung	37
4.2.1	Fragebogendesign	37
4.3	Analyse und Auswertung.....	41
4.3.1	Datenaufbereitung	42
4.3.2	Stichprobeanalyse	42
4.3.3	Vorbereitende Analyse.....	45
4.3.4	Überprüfung der Voraussetzungen für die Hypothesenprüfung.....	50
5	Interpretation der Ergebnisse.....	56
5.1	Hypothesenüberprüfung	56
5.1.1	Überprüfung von H1.....	56
5.1.2	Überprüfung von H2.....	58
5.1.3	Überprüfung von H3.....	60
5.1.4	Überprüfung von H4.....	62
5.1.5	Überprüfung von H5.....	65
6	Zusammenfassung und Handlungsempfehlungen	72
6.1	Zusammenfassung der Ergebnisse	72
6.2	Diskussion der Ergebnisse	76
6.3	Limitationen und weiterführende Forschung	78
6.4	Implikationen für die Praxis	80
	Literaturverzeichnis	83
	Abbildungsverzeichnis	94
	Tabellenverzeichnis	96
	Anhang.....	97

1 Einleitung

In diesem Kapitel wird einleitend die Problemstellung geschildert. Aufbauend darauf, wird die Forschungsfrage vorgestellt und Ziel der Arbeit dargestellt. Abschließend wird die Methodik der Arbeit erläutert.

1.1 Problemstellung

Die rasante Entwicklung von künstlicher Intelligenz (KI) hat tiefgreifende Veränderungen in verschiedenen Bereichen bewirkt, insbesondere in Businessmodellen, indem sie die Produktivität erheblich steigert und innovative Lösungen für eine Vielzahl von Problemen ermöglicht (Chauhan, Parida & Dhir, 2022, S. 1). Mit der zunehmenden Relevanz von KI in der Wirtschaft wächst auch das Interesse an der Erforschung dieser Technologie und die Relevanz von KI steigt in unterschiedlichen Forschungsbereichen. Dies zeigt sich auch an der Anzahl von publizierten KI-relevanten Artikeln. Abbildung 1 zeigt die Anzahl der Forschungsartikel, die bis 2022 publiziert wurden (Dwivedi et al., 2023, S. 6).




Abbildung 1: Anzahl der AI-relevanten, publizierten Artikel bis zum Jahr 2022 (Dwivedi et al., 2023, S. 6).

Die Forschung zu KI hat eine bemerkenswerte Vielfalt an Themen hervorgebracht, darunter die Anwendung in Bereichen wie Gesundheitswesen, Kreislaufwirtschaft und nachhaltige Lieferketten, die Akzeptanz von KI durch Konsumenten sowie die Unterstützung von Entscheidungsfindungen. Diese Themen spiegeln die großen Forschungstrends in diesem Bereich wider. Darüber hinaus hat KI-Forschung signifikante

Auswirkungen auf Disziplinen wie Betriebswirtschaft, Management, Sozialwissenschaften, Ingenieurwesen, Informatik und Mathematik (Dwivedi et al., 2023, S. 11).

Insbesondere im Marketing hat KI ihr Potenzial unter Beweis gestellt. Sie bietet fortschrittliche Tools und Einblicke für Marketingexpert:innen, die eine beispiellose Effizienz, Personalisierung und strategische Kampagnenplanung ermöglichen. Gleichzeitig gibt es jedoch auch Einschränkungen und potenzielle Herausforderungen im Zusammenhang mit dem Einsatz von KI, wie etwa Fragen des Datenschutzes, der Sicherheit, von Verzerrungen sowie der möglichen Missnutzung (Kumar, Ashraf & Nadeem, 2024, S. 22f).

Durch den Einsatz von KI-Technologie ist es möglich, Verbraucherdaten und -präferenzen präzise zu analysieren, wodurch zielgerichtete Werbemaßnahmen geschaffen werden können, die zu einer höheren Kundenbindung führen. KI-gestützte Werbung ermöglicht es, Zielgruppen zu identifizieren und gezielt anzusprechen, was zu effektiveren Kampagnen führt (Bashynska, 2023, S. 106f). Darüber hinaus erlaubt die Analyse vergangener Kundendaten die Erstellung personalisierter Profile, die maßgeschneiderte Angebote und Empfehlungen ermöglichen. Dies trägt zur Verbesserung der Benutzererfahrung bei, sei es durch personalisierte Navigation oder gezielte „Nudging“-Strategien (Gao & Liu, 2022a, S. 663f).

In der Geschäftswelt spielt personalisierte Werbung eine wichtige Rolle, um positive Effekte zu erzielen (Camilleri, 2018, S. 29f). Künstliche Intelligenz eröffnet neue Möglichkeiten, personalisierte Werbung, insbesondere in Form von Online-Werbeanzeigen, umzusetzen. Diese Arbeit untersucht die Auswirkungen von KI-gestützter Personalisierung in Online-Werbeanzeigen. Dabei wird analysiert, ob personalisierte Werbeinhalte tatsächlich zu einer höheren Conversion-Rate führen und gegebenenfalls auch negative Reaktionen hervorrufen können, etwa durch das Gefühl der Überwachung oder Manipulation. Ein zentraler Aspekt der Untersuchung ist es, die Mechanismen zu identifizieren, durch die Personalisierung wirkt, sowie die Bedingungen zu bestimmen, unter denen sie am effektivsten eingesetzt werden kann.

In der Geschäftswelt spielt personalisierte Werbung eine entscheidende Rolle, um positive Effekte zu erzielen und Zielgruppen effektiv anzusprechen (Camilleri, 2018, S. 29f). KI eröffnet in diesem Bereich neue Möglichkeiten, insbesondere im Kontext von Online-Werbeanzeigen. Die Fähigkeit, Inhalte auf die spezifischen Präferenzen und Bedürfnisse einzelner Konsument:innen zuzuschneiden, hat das Potenzial, die Effektivität von Werbemaßnahmen erheblich zu steigern.

1.2 Forschungsfrage und Ziel der Arbeit

Diese Arbeit widmet sich der Untersuchung der Auswirkungen KI-gestützter Personalisierung in Online-Werbeanzeigen. Im Fokus steht die Frage, ob personalisierte Werbeanhalte tatsächlich zu einer höheren Conversion-Rate führen und inwieweit mögliche negative Reaktionen auftreten können, wie etwa das Gefühl der Überwachung oder Manipulation. Ein zentraler Aspekt dieser Untersuchung ist es, die Mechanismen zu identifizieren, durch die Personalisierung funktioniert, und die Bedingungen zu analysieren, unter denen sie am effektivsten eingesetzt werden kann.

Diese Masterarbeit beschäftigt sich demnach mit der Fragestellung:

„Welche Auswirkungen hat die Nutzung von KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Kaufverhalten der Konsument:innen?“

Die Erforschung der Wirkung von KI-gestützter Personalisierung in der Werbung leistet einen wertvollen Beitrag zur theoretischen Debatte über den Einfluss von Technologie auf Konsumentenverhalten und Marketingstrategien. Sie ermöglicht ein tieferes Verständnis der psychologischen Mechanismen, die hinter personalisierten Empfehlungen stehen, und erweitert das Wissen über die Balance zwischen effektiver Personalisierung und der Wahrung der Privatsphäre.

Für Marketingfachleute und Unternehmen ist es essenziell, die optimalen Einsatzmöglichkeiten von KI-gestützter Personalisierung zu verstehen, um den Return on Investment (ROI) zu maximieren. Präzise Personalisierung kann nicht nur die Effizienz von Marketingkampagnen steigern, sondern auch die Kundenbindung stärken, indem sie individuell zugeschnittene Erlebnisse bietet (Coelho, Vilares & Ball, 2006, S. 391f). Diese Arbeit liefert wertvolle Erkenntnisse für die Entwicklung effektiver Werbestrategien und die Verbesserung der Kundenzufriedenheit.

Auch für Konsument:innen gewinnt das Thema zunehmend an Bedeutung. Die Untersuchung erhöht das Bewusstsein für die Funktionsweise personalisierter Technologien und deren Auswirkungen auf das Konsumverhalten in einer digitalisierten Welt. Die Balance zwischen den Vorteilen maßgeschneiderter Angebote und den potenziellen Risiken wie Überwachung und Manipulation stellt dabei einen wichtigen Aspekt dar.

Die vorliegende Arbeit trägt zur Forschung bei, indem sie empirische Daten zur Wirksamkeit von KI-gestützter Personalisierung in der Werbung bereitstellt und theoretische Modelle zur Erklärung des Konsumentenverhaltens weiterentwickelt. Sie beleuchtet differenziert die Chancen und Risiken, die mit dem Einsatz von KI einhergehen, und liefert wichtige Impulse zur Formulierung von Best Practices für Unternehmen. Diese können

genutzt werden, um fundierte Entscheidungen zu treffen, ethische Standards einzuhalten und die Potenziale von KI in der Werbung nachhaltig und verantwortungsvoll auszuschöpfen.

1.3 Aufbau der Arbeit

Im zweiten Kapitel werden die theoretischen Grundlagen erläutert, die für diese Arbeit von Bedeutung sind. Dabei werden sowohl allgemeine Marketingkonzepte als auch KI-relevante Ansätze vorgestellt, die die Basis für die weitere Untersuchung bilden.

Das dritte Kapitel widmet sich einer Übersicht über bereits existierende wissenschaftliche Arbeiten zu KI-gestützten Anwendungen im Marketing. Der Schwerpunkt liegt dabei auf dem Bereich der Personalisierung, um einen umfassenden Überblick über den aktuellen Forschungsstand und die praktischen Anwendungen zu geben.

Aufbauend auf diesen Grundlagen wird im vierten Kapitel die empirische Untersuchung vorgestellt. Dieses Kapitel beschreibt die Methodik, die Datenerhebung und den Ablauf der Analyse.

Im fünften Kapitel werden schließlich die Ergebnisse der empirischen Untersuchung detailliert analysiert und interpretiert. Hierbei wird ein besonderer Fokus auf die Implikationen der Ergebnisse für die Praxis sowie auf deren Beitrag zur bestehenden Forschung gelegt.

2 Theoretische Grundlagen

Dieses Kapitel dient dazu, die theoretischen Grundlagen zu erläutern und ein gemeinsames Verständnis für die empirische Untersuchung zu schaffen. Zu Beginn werden die grundlegenden Konzepte des Marketings vorgestellt, die als Basis für die Betrachtung der Personalisierung und KI-gestützten Ansätze dienen. Danach werden theoretische Modelle zur Erklärung von Konsumentenverhalten und Kaufabsichten vorgestellt. Anschließend werden die relevanten Grundlagen der künstlichen Intelligenz beschrieben, um die spezifischen Technologien und Mechanismen, die in dieser Arbeit thematisiert werden, nachvollziehbar zu machen.

2.1 Marketing

Marketing wird in der wissenschaftlichen Literatur als eine unternehmerische Denkhaltung verstanden, die sämtliche Unternehmensaktivitäten konsequent an den Bedürfnissen des Marktes ausrichtet. Ziel ist es, durch Analyse, Planung, Umsetzung und Kontrolle interner und externer Maßnahmen den Kundennutzen zu maximieren und absatzmarktorientierte Unternehmensziele zu erreichen (Bruhn, 2022, S. 2).

Ein zentraler Bestandteil jeder Organisation besteht darin, Kund:innen durch gezielte Aktivitäten und Prozesse einen klaren Mehrwert zu bieten. Dabei spielt der Markt eine entscheidende Rolle, da er eine Gruppe potenzieller Kund:innen umfasst, das Interesse an einem bestimmten Produkt oder einer spezifischen Dienstleistung zeigen. Innerhalb dieses Marktes lassen sich durch gezielte Ansprache sogenannte Marktsegmente identifizieren, also Teilmärkte, die sich durch gemeinsame Merkmale und Bedürfnisse auszeichnen. Ein wichtiges Konzept in diesem Zusammenhang ist das Marketing-Mix-Modell der vier Ps nach Adhikary, das die zentralen Steuerungsgrößen Produkt, Preis, Platzierung und Promotion beschreibt und als Grundlage für eine erfolgreiche Marktstrategie dient (Adhikary, 2014, S. 230).

- Produkt: Produkte oder Dienstleistungen, die ein Kundenproblem lösen.
- Place (Distribution): Der Weg, wie Produkte zu den Kund:innen gelangen.
- Promotion (Kommunikation): Die Vermittlung der Produktmerkmale und des Wertangebots.
- Price (Preis): Der Austausch von Wert zwischen Kunde und Unternehmen.

Ein wesentlicher Aspekt der Online-Werbung ist ihre doppelte Funktion. Sie dient einerseits der Information der Konsument:innen, indem sie Produkteigenschaften und Markenwerte vermittelt, und andererseits der Überzeugung, indem sie das Verhalten und die Präferenzen der Verbraucher gezielt beeinflusst. Mit personalisierten und

ansprechenden Inhalten schafft Online-Werbung Markenbewusstsein und lenkt Entscheidungen zugunsten des beworbenen Produkts oder der Dienstleistung (Wiktor & Sanak-Kosmowska, 2021, S. 4158f).

2.1.1 Digitalisierung und Wandel im Marketing

Die digitale Transformation hat die Art und Weise, wie Unternehmen Werbung betreiben, grundlegend verändert. Neue Technologien und Plattformen wie Social-Media, Content-Marketing und personalisierte Werbung eröffnen Unternehmen vielfältige Möglichkeiten, mit Kund:innen in Echtzeit zu interagieren und deren Kaufentscheidungen direkt zu beeinflussen. Gleichzeitig wird deutlich, dass Online-Werbung in wettbewerbsintensiven Märkten ein entscheidender Faktor ist, um sich von der Konkurrenz abzuheben. Unternehmen überwachen nicht nur die Werbeaktivitäten ihrer Mitbewerber, sondern entwickeln gezielte Strategien, um Aufmerksamkeit zu gewinnen und die Präferenzen ihrer Zielgruppen zu dominieren (Wiktor & Sanak-Kosmowska, 2021, S. 4158ff).

Digitales Marketing beschreibt sämtliche Marketingmaßnahmen, die unter Nutzung digitaler Technologien, wie zum Beispiel das Internet, realisiert werden. Im Unterschied zum traditionellen Marketing, das stark auf klassische Kanäle wie Print, TV oder Radio setzt, basiert digitales Marketing auf datengetriebenen Ansätzen. Ziel ist es, durch die gezielte Erhebung, Analyse und Nutzung von Nutzerdaten eine präzisere, personalisierte und interaktivere Kundenansprache zu ermöglichen (Chaffey & Ellis-Chadwick, 2019, S. 8). Wesentliche Merkmale sind die direkte Messbarkeit von Erfolgen, die Möglichkeit zur Echtzeitanpassung von Kampagnen sowie die Interaktivität zwischen Marke und Konsument:innen.

Während im traditionellen Marketing häufig Massenkommunikation ohne individuelle Adressierung dominiert, basiert digitales Marketing auf einer differenzierten Zielgruppenansprache bis hin zur Ansprache einzelner Nutzer:innen. Diese Individualisierung ist nur durch die Integration von Technologien wie Big Data, Tracking-Tools, Algorithmen und Künstlicher Intelligenz möglich, die datengetriebene Entscheidungen ermöglichen (Tuten & Solomon, 2021, S. 4). Durch diese Entwicklung wird Marketing zunehmend automatisiert und dynamisch. Dies wird vor allem im Online-Werbung verdeutlicht. Diese technologische Grundlage personalisierter Werbung macht Online-Kommunikation zu einem strategischen Instrument im Wettbewerb (Wiktor & Sanak-Kosmowska, 2021, S. 4158ff). Die nächste Abbildung zeigt, in welchem Ausmaß Unternehmen Online-Werbung gezielt zur Positionierung im Branchenwettbewerb einsetzen:




Abbildung 2: Einschätzung polnischer Unternehmen zur wettbewerbsbezogenen Funktion von Online-Werbung (Wiktor & Sanak-Kosmowska, 2021, S. 4164).

Die strategische Relevanz digitaler Werbung zeigt sich auch in ihrer wachsenden Bedeutung für den unternehmerischen Wettbewerb. Wie Abbildung 2 veranschaulicht, stimmen über 70 % der befragten polnischen Unternehmen der Aussage zu, dass Online-Werbung eine zentrale Rolle im sektoralen Wettbewerb einnimmt und aktiv zur Positionierung gegenüber Mitbewerbern genutzt wird (Wiktor & Sanak-Kosmowska, 2021, S. 4164).

2.1.2 Bedeutung von Online-Werbung im heutigen Marketing-Mix

Online-Werbung hat sich in den letzten Jahren zu einem der bedeutendsten Instrumente im Marketing-Mix entwickelt. Laut einer Analyse von Statista entfielen im Jahr 2022 weltweit über 62 % aller Werbeausgaben auf digitale Kanäle, wobei die Tendenz steigend ist und die Ausgaben größer und größer werden (Statista, 2023). Besonders dominierend sind dabei Social-Media-Werbung, Suchmaschinenmarketing sowie Display-Advertising, die häufig durch datenbasierte Personalisierung ergänzt werden.

Die Gründe für diese Entwicklung liegen in der Effizienz, Skalierbarkeit und Messbarkeit digitaler Werbung. Unternehmen können über Online-Plattformen zielgerichtete Kampagnen gestalten, in Echtzeit reagieren und gleichzeitig eine Vielzahl an Metriken, wie

zum Beispiel Klickraten, Conversion Rates oder Verweildauer, zur Optimierung heranziehen (Yuan, Wang, Li & Qin, 2014, S. 418).

Gerade im Kontext der zunehmenden Verbreitung mobiler Endgeräte und des 24/7-Zugriffs auf Inhalte steigt die Relevanz, Konsument:innen zur richtigen Zeit am richtigen Ort mit relevanten Botschaften zu erreichen. In diesem Umfeld erweist sich Online-Werbung, wie vor allem Werbungen, die durch KI personalisiert werden, als entscheidender Erfolgsfaktor im Wettbewerb um Aufmerksamkeit und Kaufentscheidungen.

2.1.3 Online-Werbeanzeigen & Personalisierung

Die digitale Transformation hat der Werbeindustrie ein mächtiges Werkzeug in die Hand gegeben: die KI-gestützte Personalisierung. Durch die Fähigkeit moderner Algorithmen, enorme Mengen an Daten zu analysieren, können Unternehmen Anzeigen gestalten, die auf einzelne Nutzer:innen zugeschnitten sind (Neumann, Tucker & Whitfield, 2019, S. 918). Diese präzise Ausrichtung hat nicht nur das Potenzial, die Relevanz der Werbung für jede Person zu erhöhen, sondern auch die Effizienz ganzer Marketingkampagnen zu steigern (Boerman, Kruikemeier & Bol, 2021, S. 1).

Personalisierung bedeutet in diesem Zusammenhang die Anpassung von Dienstleistungen oder Produkten, um den spezifischen Anforderungen und Vorlieben der Kund:innen zu entsprechen. Dies kann von der einfachen Gestaltung individueller Inhalte bis zur gezielten Ansprache bestimmter Nutzergruppen reichen. In der Welt der Online-Werbung hat sich diese Methode zu einem der wirkungsvollsten Werkzeuge entwickelt, das Unternehmen zur Verfügung steht, um ihre Zielgruppen besser zu erreichen und langfristige Kundenbeziehungen aufzubauen (Coelho et al., 2006, S. 391).

Die Arten der Personalisierung lassen sich in zwei zentrale Ansätze unterteilen. Zum einen gibt es die Inhalts-Personalisierung, bei der die Inhalte einer Anzeige an individuelle Merkmale wie Alter, Interessen oder Online-Verhalten angepasst werden. Zum anderen gibt es das Targeting, bei dem Anzeigen basierend auf gesammelten Daten spezifischen Zielgruppen oder Personen gezeigt werden. Beispiele hierfür sind die Anpassung von Anzeigen an den Standort, den Suchverlauf oder das Einkaufsverhalten von Nutzer:innen. Beide Ansätze ermöglichen es Unternehmen, eine hohe Präzision in der Ansprache ihrer Zielgruppen zu erreichen und gleichzeitig die Relevanz der Werbung aus Sicht der Konsumenten zu steigern (Coelho et al., 2006, S. 391).

Die Mechanismen hinter der personalisierten Werbung basieren auf der Anpassung der Inhalte von Werbeanzeigen an individuelle Interessen, Bedürfnisse und Verhaltensmuster der Nutzer:innen. Wenn beispielsweise jemand regelmäßig Artikel über Fitness liest

oder Fitnessprodukte kauft, könnten Anzeigen für Sportbekleidung oder Fitnessgeräte bevorzugt angezeigt werden. Gleichzeitig werden Anzeigen spezifischen Zielgruppen oder sogar einzelnen Personen gezeigt, basierend auf deren Daten wie Standort, Suchverlauf oder Kaufhistorie. So können etwa reisende Personen, die kürzlich nach Hotels in Paris gesucht hat, gezielt Angebote für Flüge, Hotels oder Stadtrundgänge erhalten. Beide Methoden ergänzen sich und bieten zusammen eine äußerst präzise Möglichkeit, Konsument:innen zu erreichen und ihre Aufmerksamkeit zu gewinnen (Boerman et al., 2021, S. 1).

Personalisierte Werbung wirkt auf mehreren Ebenen. Für Konsument:innen bedeutet sie in erster Linie eine höhere Relevanz der angezeigten Inhalte. Anzeigen, die gezielt auf die Interessen und Bedürfnisse der Nutzer zugeschnitten sind, werden nicht als störend empfunden, sondern eher als hilfreich oder informativ. Diese positive Wahrnehmung kann dazu führen, dass Konsument:innen der Marke gegenüber aufgeschlossener sind, was wiederum ihre Kaufbereitschaft steigert. Auf Seiten der Unternehmen resultiert dies in einer effizienteren Nutzung von Ressourcen. Anstatt Streuverluste zu erzeugen, können Werbekampagnen gezielt dort ansetzen, wo sie die höchste Wirkung entfalten. Gleichzeitig eröffnen sich durch die Personalisierung wirtschaftliche Vorteile. Rabatte, die auf das Kaufverhalten abgestimmt sind, oder maßgeschneiderte Angebote verbessern nicht nur die Kundenzufriedenheit, sondern können auch die Umsätze signifikant steigern (Coelho et al., 2006, S. 391).

So viele Chancen die personalisierte Werbung auch bietet, so groß sind die Herausforderungen, die sie mit sich bringt. Insbesondere der Umgang mit persönlichen Daten stellt Unternehmen vor eine heikle Aufgabe. Verbraucher:innen sind zunehmend sensibilisiert für Themen wie Datenschutz und Privatsphäre. In diesem Kontext ist Transparenz der Schlüssel. Nutzer:innen möchten wissen, wie ihre Daten verwendet werden, welche Algorithmen dahinterstecken und welche Vorteile sie selbst daraus ziehen können. Ein weiteres ethisches Dilemma ergibt sich aus der Möglichkeit, Preise und Botschaften dynamisch anzupassen. Obwohl diese Flexibilität aus unternehmerischer Sicht attraktiv ist, kann sie bei Verbraucher:innen den Eindruck von Ungerechtigkeit oder Manipulation hervorrufen (Boerman et al., 2021, S. 2).

2.2 Theoretische Modelle zur Erklärung von Konsumentenverhalten und Kaufabsichten

Zur Erklärung von Konsumentenverhalten und Kaufabsichten bieten verschiedene theoretische Modelle wertvolle Ansätze. Dieses Kapitel beleuchtet die Theory of Planned Behavior, das Elaboration Likelihood Model, das Technology Acceptance Model sowie

das Konzept der Attitude Toward the Ad und der Purchase Intention. Gemeinsam liefern sie ein fundiertes Verständnis darüber, wie Einstellungen, Werbewirkung und Technologieakzeptanz Kaufentscheidungen beeinflussen.

2.2.1 Theory of Planned Behaviour (TPB)

Die TPB, entwickelt von Icek Ajzen, ist ein bedeutendes Modell zur Erklärung und Vorhersage menschlichen Verhaltens. Sie basiert auf der Annahme, dass das Verhalten einer Person maßgeblich von ihrer Intention bestimmt wird, ein bestimmtes Verhalten auszuführen. Diese Intention stellt den stärksten Prädiktor für tatsächliches Verhalten dar und wird von drei zentralen Faktoren der Einstellung gegenüber dem Verhalten, der subjektiven Norm sowie der wahrgenommenen Verhaltenskontrolle beeinflusst. Die TPB erweitert die „Theory of Reasoned Action“. Dieses Modell beschreibt das Verhalten durch die Kombination von Einstellung und subjektiver Norm und erweitert es um den Aspekt der Verhaltenskontrolle, um auch Handlungen zu berücksichtigen, die nicht vollständig unter der willentlichen Kontrolle der Person stehen (Ajzen, 1991, S. 179).

Die Einstellung gegenüber dem Verhalten bezieht sich auf die persönliche Bewertung eines Verhaltens, die auf Überzeugungen über die erwarteten Konsequenzen basiert. Positive Erwartungen, wie etwa der Nutzen oder die Freude an einem bestimmten Verhalten, erhöhen die Wahrscheinlichkeit, dass eine Person dieses Verhalten beabsichtigt. Die subjektive Norm hingegen beschreibt den wahrgenommenen sozialen Druck, ein Verhalten auszuführen oder zu unterlassen. Sie wird von den Meinungen wichtiger Bezugspersonen beeinflusst, wie Familie, Freunde oder Kollegen, und reflektiert, inwiefern eine Person glaubt, dass andere ihr Verhalten unterstützen oder ablehnen (Ajzen, 1991, S. 179).

Ein zentrales Element der TPB ist die wahrgenommene Verhaltenskontrolle, die das subjektive Empfinden einer Person beschreibt, inwiefern sie glaubt, über die notwendigen Ressourcen, Fähigkeiten und Möglichkeiten zu verfügen, um ein bestimmtes Verhalten auszuführen. Sie beeinflusst nicht nur die Intention, sondern kann in Situationen mit eingeschränkter Kontrolle auch direkt das Verhalten bestimmen. Das Zusammenspiel dieser drei Faktoren, Einstellung, subjektive Norm und wahrgenommene Verhaltenskontrolle, ermöglicht es, menschliches Verhalten in verschiedenen Kontexten, wie Konsumentenverhalten, Gesundheitsförderung oder Technologieakzeptanz, präzise zu erklären und vorherzusagen (Ajzen, 1991, S. 179).

Ein praktisches Anwendungsbeispiel für die TPB bietet die Arbeit von Ajzen und Sheikh. In ihrer Studie untersuchten sie die Rolle erwarteter Emotionen im Entscheidungsprozess, insbesondere im Spannungsfeld zwischen Aktion und Nicht-Aktion. Die

Ergebnisse zeigen, dass neben der klassischen Intention auch erwartete Emotionen wie Freude oder Bedauern einen signifikanten Einfluss auf das Verhalten ausüben können. Im Kontext von KI-gestützter Online-Werbung bedeutet dies, dass personalisierte Anzeigen nicht nur auf rationaler Ebene wirken, sondern auch positive emotionale Erwartungen hervorrufen sollten, um eine stärkere Kaufabsicht zu generieren. Die Erweiterung der TPB um emotionale Komponenten wird damit besonders für die Gestaltung wirksamer Werbemaßnahmen relevant (Ajzen & Sheikh, 2013, S. 155).

Eine weitere Anwendung der TPB im Bereich der digitalen Werbung findet sich in der Untersuchung von Alalwan. Die Studie analysierte, wie verschiedene Eigenschaften von Social-Media-Werbung, wie zum Beispiel Informationsgehalt, Unterhaltungswert und Interaktivität, die drei zentralen TPB-Komponenten beeinflussen, nämlich die Einstellung gegenüber dem Verhalten, die subjektive Norm sowie die wahrgenommene Verhaltenskontrolle. Die Ergebnisse belegen, dass der wahrgenommene Nutzen der Werbeanzeigen eine positive Einstellung zum Produkt fördert, während die Interaktivität die subjektive Norm beeinflusst, indem sie soziale Bestätigung erleichtert. Darüber hinaus steigert eine intuitive Benutzerführung die wahrgenommene Verhaltenskontrolle und damit die Kaufabsicht der Konsument:innen. Diese Erkenntnisse verdeutlichen, wie Online-Werbung gezielt gestaltet werden kann, um zentrale Determinanten der Verhaltensabsicht positiv zu beeinflussen (Alalwan, 2018, S. 65).

Darüber hinaus spielt die Wahrnehmung von Datenschutz und Privatsphäre im digitalen Umfeld eine wesentliche Rolle für die Anwendung der TPB. Bélanger und Crossler zeigen in ihrer Arbeit, dass das Gefühl der Kontrolle über persönliche Informationen ein entscheidender Faktor für die Verhaltensintention im Online-Kontext ist. Insbesondere im Zusammenhang mit KI-gestützter Personalisierung kann eine wahrgenommene Unsicherheit bezüglich der Datennutzung die Kaufabsicht erheblich verringern. Die Studie unterstreicht, dass Datenschutz nicht nur ein ethisches Thema ist, sondern auch ein zentraler psychologischer Einflussfaktor auf das Konsumentenverhalten. Somit erweitert die Wahrnehmung von Datenschutz die klassische Komponente der wahrgenommenen Verhaltenskontrolle innerhalb der TPB um einen aktuellen und praxisrelevanten Aspekt (Bélanger & Crossler, 2011, S. 1017).

2.2.2 Elaboration Likelihood Model (ELM)

Das Elaboration Likelihood Model (ELM) ist ein Modell der Persuasionsforschung, das von Richard E. Petty und John T. Cacioppo in den 1980er Jahren entwickelt wurde. Es beschreibt die Mechanismen, durch die überzeugende Botschaften verarbeitet werden und welche Faktoren die Wahrscheinlichkeit der Einstellungsänderung beeinflussen.

Grundlegend unterscheidet das Modell zwischen zwei Wegen der Informationsverarbeitung: dem zentralen und dem peripheren Weg. Diese Struktur erlaubt es, die Komplexität von Einstellungsänderungen in verschiedenen Kontexten differenziert zu analysieren (Petty & Cacioppo, 1986, S. 5).

Der zentrale Weg der Informationsverarbeitung ist gekennzeichnet durch eine intensive kognitive Auseinandersetzung mit den Argumenten der Botschaft. Personen, die diesen Weg einschlagen, verfügen über eine hohe Motivation und Fähigkeit, die präsentierten Informationen kritisch zu evaluieren. Die resultierenden Einstellungsänderungen sind in der Regel stabil, widerstandsfähig gegenüber Gegenargumenten und verhaltensrelevant. Typische Einflussfaktoren auf diesem Weg sind die Qualität und Logik der Argumente sowie die Relevanz des Themas für die betreffende Person. Im Gegensatz dazu beruht der periphere Weg auf oberflächlichen Hinweisreizen, wie etwa der Attraktivität des Kommunikators, der Häufigkeit der Wiederholung der Botschaft oder emotionalen Appellen. Personen neigen zu dieser Form der Verarbeitung, wenn ihre Motivation oder Fähigkeit zur tieferen Auseinandersetzung gering ist. Einstellungsänderungen, die über den peripheren Weg erreicht werden, sind meist weniger stabil und anfälliger für nachträgliche Beeinflussungen (Petty & Cacioppo, 1986, S. 5).

Das ELM bietet nicht nur ein theoretisches Rahmenwerk zur Erklärung von Persuasionsprozessen, sondern auch praktische Implikationen für die Gestaltung effektiver Kommunikationsstrategien in Bereichen wie Werbung, Politik und Gesundheitsaufklärung. Indem es den Einfluss von individuellen und situativen Faktoren auf den Verarbeitungsweg betont, liefert das Modell wertvolle Einsichten darüber, wie und warum Menschen ihre Einstellungen ändern (Petty & Cacioppo, 1986, S. 5).

Aktuelle Forschung zum Verbraucherverhalten im Live-Commerce illustriert die Anwendbarkeit des ELM in digitalen Verkaufssituationen. Wang et al. zeigen, dass zentrale Hinweisreize wie detaillierte Produktinformationen, transparente Preisangaben und fundierte Erklärungen des Streamers signifikant die Wahrscheinlichkeit erhöhen, dass Konsument:innen den zentralen Verarbeitungsweg einschlagen. Dies setzt voraus, dass sowohl Motivation als auch Fähigkeit zur intensiven kognitiven Auseinandersetzung vorhanden sind. Gleichzeitig wirken periphere Hinweisreize, wie etwa die physische Attraktivität oder die Popularität der Streamer:innen, insbesondere auf weniger involvierte Rezipient:innen ein, die aufgrund begrenzter Motivation oder kognitiver Ressourcen auf heuristische Verarbeitungsstrategien zurückgreifen (Wang, Chen & Li, 2024, S. 1). Die Studie bestätigt somit die zentrale Annahme des ELM, dass sowohl personen- als auch situationsabhängige Einflussfaktoren bestimmen, welcher Verarbeitungsweg bevorzugt

wird. Weiters betont die Arbeit die Relevanz einer differenzierten Kommunikationsstrategie im Live-Commerce.

Auch im Bereich der sozialen Medienwerbung konnte die Relevanz der Verarbeitungswege des ELM empirisch untermauert werden. Zhang et al. identifizierten in ihrer Untersuchung, dass ein hoher Grad an Interaktivität innerhalb von Werbeanzeigen, etwa durch direkte Nutzerbeteiligung oder Echtzeit-Feedback, die kognitive Involvierung der Rezipient:innen signifikant steigert und damit die Wahrscheinlichkeit einer zentralen Informationsverarbeitung erhöht. Wird hingegen eine geringere Interaktivität geboten, erfolgt die Verarbeitung primär über periphere Hinweisreize wie die visuelle Gestaltung oder die Anzahl an Likes und Kommentaren. Diese Ergebnisse stimmen mit der Grundannahme des ELM überein, dass situative Faktoren, in dem Fall die Interaktivität, einen entscheidenden Einfluss darauf haben, ob eine stabile Einstellungsänderung erzielt werden kann (Zhang & Zhao, 2023, S. 1). Für die Praxis bedeutet das, dass Werbetreibende durch gezielte Gestaltung interaktiver Elemente in sozialen Medien überzeugen können.

Im Kontext der zunehmenden Verbreitung KI-gestützter Werbeanzeigen wird die Erklärungskraft des ELM ebenfalls deutlich. Liu et al. konnten zeigen, dass die wahrgenommene Kompetenz und Authentizität von KI-generierten Werbeinhalten als zentrale Hinweisreize wirken und die Motivation der Rezipient:innen fördern, sich intensiv mit den Werbeinhalten auseinanderzusetzen. Diese Wahrnehmungen begünstigen den Übergang zur zentralen Verarbeitungsrouten, was wiederum zu stabileren und handlungsrelevanten Einstellungsänderungen führt. Gleichzeitig kann das Erleben von Unbehagen als peripherer Hinweisreiz wirken und die Akzeptanz sowie die kognitive Tiefe der Verarbeitung verringern (Gu, Jia, Lai, Chen & Chang, 2024, S. 2218). Diese Ergebnisse der Studie erweitern die Anwendungsperspektive des ELM auf neue technologische Entwicklungen und betonen, bei der Gestaltung KI-gestützter Werbung sowohl kognitive als auch affektive Reaktionen der Konsument:innen zu berücksichtigen, um die erwünschten Wirkungen auf das Kaufverhalten zu maximieren.

2.2.3 Technology Acceptance Model (TAM)

Der Artikel von Fred D. Davis befasst sich mit der Akzeptanz von Informationstechnologie und entwickelt sowie validiert Messskalen für zwei zentrale Konstrukte: wahrgenommene Nützlichkeit und wahrgenommene Benutzerfreundlichkeit. Diese Variablen werden als grundlegende Einflussfaktoren für die Nutzung von Computersystemen betrachtet. Im Rahmen der Untersuchung wurden zwei empirische Studien mit insgesamt 152 Teilnehmer:innen durchgeführt, um die psychometrische Validität der entwickelten Skalen zu überprüfen. Der Begriff psychometrisch beschreibt die wissenschaftliche Messung

psychologischer Eigenschaften, wie Wahrnehmungen oder Einstellungen, durch standardisierte Verfahren. Die Ergebnisse der Studie zeigen, dass die wahrgenommene Nützlichkeit einen stärkeren Einfluss auf die Systemnutzung hat als die Benutzerfreundlichkeit (Davis, 1989, S. 319). Die folgende Abbildung visualisiert das Model von Davis:




Abbildung 3: Die Visualisierung des Technology Acceptance Model (Davis, 1989, S. 320).

Die wahrgenommene Nützlichkeit wird als „das Maß, in dem eine Person glaubt, dass die Nutzung eines bestimmten Systems ihre Arbeitsleistung verbessern würde“ definiert. Diese Definition basiert auf der allgemeinen Bedeutung des Begriffs „nützlich“, der als „vorteilhaft verwendbar“ interpretiert wird. In einem organisatorischen Kontext bedeutet dies, dass Systeme mit hoher wahrgenommener Nützlichkeit von den Nutzer:innen als leistungssteigernd wahrgenommen werden und daher eine höhere Akzeptanz erfahren (Davis, 1989, S. 320).

In einer empirischen Untersuchung zeigen Zhao et al., dass sowohl die wahrgenommene Nützlichkeit als auch die Benutzerfreundlichkeit von KI-basierten Systemen signifikant die Nutzungsabsicht von Konsument:innen beeinflussen. Besonders deutlich wird, dass eine als vorteilhaft empfundene Integration von KI in Online-Shopping-Plattformen die Akzeptanz fördert und die Kaufbereitschaft steigert, während komplexe oder schwer verständliche Interfaces die Nutzung hemmen. Diese Ergebnisse unterstreichen die Relevanz des TAM zur Erklärung der Akzeptanz innovativer Technologien im E-Commerce und verdeutlichen, dass speziell bei KI-gestützter Personalisierung die Nutzererfahrung klar und intuitiv gestaltet werden muss, um positive Effekte auf das Kaufverhalten zu erzielen (Zhao, Chen & Singh, 2023, S. e12600).

In Bezug auf personalisierter Werbung auf Social-Media-Plattformen konnte die Erklärungskraft des TAM wieder bestätigt werden. Zhang et al. untersuchten die

Einflussfaktoren auf die Akzeptanz von KI-basierten Werbeanzeigen und fanden heraus, dass wahrgenommene Benutzerfreundlichkeit und Nützlichkeit, ergänzt um das Vertrauen in die KI-Systeme, zentrale Einflussfaktoren der Akzeptanz sind. Besonders relevant ist, dass hohe Personalisierung und adaptive Anpassung der Werbeinhalte an Nutzerpräferenzen die positive Wahrnehmung der Nützlichkeit steigern, während mangelnde Transparenz Vertrauen und Akzeptanz erheblich mindern kann. Die Studie zeigt, dass neben klassischen Aspekten in TAM auch neue Faktoren wie Vertrauen in die KI eine entscheidende Rolle im Kontext personalisierter Werbung spielen (Zhang, Liu & Huang, 2024, S. 11273900).

Die zunehmende Integration von künstlicher Intelligenz in die Kundenansprache verdeutlicht ebenfalls die Aktualität und die Relevanz des Technology Acceptance Model. Kim et al. analysierten den Einfluss personalisierter KI-Interaktionen im Online-Shopping und fanden, dass wahrgenommene Nützlichkeit als stärkster Einflussfaktor auf die Kaufentscheidung wirkt, während wahrgenommene Benutzerfreundlichkeit insbesondere die Erstnutzung unterstützt. Ergänzend wird deutlich, dass eine positive Erfahrung mit KI-gesteuerten Empfehlungen die Wahrscheinlichkeit einer wiederholten Nutzung und langfristigen Kundenbindung erhöht. Die Ergebnisse der Studie erweitern damit das Verständnis von TAM im Bereich der KI-basierten Personalisierung und legen nahe, dass bei der Gestaltung personalisierter Systeme neben der Funktionalität auch gezielt auf eine positive Nutzererfahrung geachtet werden sollte, um nachhaltige Verhaltensänderungen zu erreichen (Nagy & Hajdú, 2021, S. 155).

2.2.4 Attitude Toward the Ad (ATTA)

Die Einstellung gegenüber einer Werbeanzeige (ATTA) spielt eine zentrale Rolle in der Werbewirkungsforschung, da sie als vermittelnde Einflussfaktor zwischen Werberezeption und Markenbewertung betrachtet wird. Die Studie von MacKenzie et al. untersucht verschiedene theoretische Modelle, um den Einfluss von ATTA auf die Wahrnehmung der Marke und die Kaufabsicht zu analysieren. Die Autor:innen vergleichen vier konkurrierende Erklärungsansätze, die sich in der Art unterscheiden, wie sie die Beziehung zwischen Werbeanzeige, Markenbewertung und Kaufabsicht modellieren. Die empirischen Untersuchungen basieren auf zwei experimentellen Studien mit einem kommerziellen Pretest-Setting, in dem Teilnehmer:innen verschiedene Werbeanzeigen bewerteten. Die Ergebnisse zeigen, dass das Modell der doppelten Mediation die beste Erklärung für die Werbewirkung liefert. Dieses Modell besagt, dass die Einstellung gegenüber der Anzeige nicht nur direkt die Markenbewertung beeinflusst, sondern auch indirekt

über die Wahrnehmung der markenbezogenen Informationen (MacKenzie, Lutz & Belch, 1986, S. 130).

Die Definition von ATTA beschreibt eine vorgeprägte positive oder negative Reaktion auf eine Werbeanzeige während einer bestimmten Exposition. Diese affektive Bewertung kann sowohl aus inhaltlichen als auch aus gestalterischen Merkmalen der Werbung resultieren. In der Forschungsliteratur wurde bereits früh darauf hingewiesen, dass Konsument:innen nicht nur kognitive, sondern auch emotionale Reaktionen auf Werbung zeigen, die wiederum ihre Wahrnehmung der Marke beeinflussen können. Das Modell der doppelten Mediation erweitert diese Perspektive, indem es zeigt, dass positive Emotionen gegenüber der Anzeige die Akzeptanz der in der Werbung kommunizierten Markenbotschaften erhöhen und somit die Kaufabsicht indirekt verstärken (MacKenzie et al., 1986, S. 130).

Psychometrisch betrachtet bedeutet dies, dass die Konstrukte in der Studie mit standardisierten Messinstrumenten erfasst wurden, um deren Validität und Reliabilität sicherzustellen. Psychometrie bezeichnet die wissenschaftliche Messung von psychologischen Merkmalen wie Einstellungen oder Wahrnehmungen durch quantitative Verfahren. Die Autor:innen verwendeten mehrdimensionale Skalen mit semantischen Differenzialen sowie kognitive Reaktionsmessungen, um die affektiven und kognitiven Prozesse bei der Werbewirkung differenziert zu erfassen (MacKenzie et al., 1986, S. 130).

Ein aktuelles Beispiel für die Bedeutung von ATTA in der digitalen Werbewirkungsforschung liefert die Studie von Mo et al., die ein strukturgleichungsbasiertes Modell zur Untersuchung personalisierter Online-Werbung entwickelt hat. In diesem Modell beeinflusst die wahrgenommene Personalisierung sowohl der Informationsgehalt als auch die Privatsphärebedenken der Nutzer:innen und wirkt somit zweifach auf die Werbeeinstellung. Sie wirkt positiv über Informationsgehalt und negativ über wahrgenommene Eingriffe in die Privatsphäre. Eine zentrale Rolle spielt dabei die sogenannte *Flow Experience*, also das Gefühl des Eintauchens in eine Aufgabe oder Reizsituation, die als vermittelnder Mechanismus fungiert (Mo, Zhang, Lin, Yuan & Peng, 2023, S. 4090).

2.2.5 Purchase Intention (PI)

Die Kaufabsicht (PI) beschreibt die Wahrscheinlichkeit, mit der Konsument:innen beabsichtigen, ein bestimmtes Produkt oder eine Dienstleistung zu erwerben. In der Forschung wird PI als ein entscheidender Indikator für das tatsächliche Kaufverhalten betrachtet. Sie wird durch verschiedene Faktoren beeinflusst, darunter persönliche Einstellungen, subjektive Wahrnehmungen sowie externe Einflüsse wie Markenimage, Preis-Leistungs-Verhältnis oder soziale Empfehlungen. In der Praxis wird PI häufig zur

Vorhersage von Konsumentenentscheidungen genutzt und dient Unternehmen als zentrale Messgröße für den Erfolg von Marketingmaßnahmen und Produktstrategien (Wang et al., 2023, S. e21617).

Im Kontext des grenzüberschreitenden E-Commerce gewinnt PI zunehmend an Bedeutung, da Konsument:innen ihre Entscheidungen unter Unsicherheit treffen müssen. Studien zeigen, dass Vertrauen in die Plattform, wahrgenommene Qualität der Produkte und ein positives Käuferlebnis entscheidende Faktoren sind, die die PI beeinflussen. Gleichzeitig können Risiken wie lange Lieferzeiten, fehlende Transparenz bei Preisen oder negative Bewertungen die Kaufabsicht verringern. Strukturgleichungsmodelle, wie sie in aktuellen Forschungsarbeiten verwendet werden, helfen dabei, diese Einflussfaktoren systematisch zu analysieren und die Mechanismen hinter der PI besser zu verstehen (Wang et al., 2023, S. e21617).

Ein umfassender Überblick über PI verdeutlicht, dass sie nicht nur von individuellen Präferenzen abhängt, sondern auch durch emotionale und kognitive Prozesse geprägt wird. Während positive Markenassoziationen und überzeugende Produktinformationen die Kaufabsicht verstärken, können Unsicherheit und negative Erfahrungen zu einer Verringerung führen. Unternehmen im E-Commerce können gezielt auf diese Faktoren einwirken, indem sie Vertrauen aufbauen, klare Informationen bereitstellen und ein nahtloses Einkaufserlebnis schaffen. Die Untersuchung von PI liefert somit nicht nur theoretische Erkenntnisse, sondern hat auch weitreichende praktische Implikationen für die Gestaltung effektiver Marketingstrategien (Wang et al., 2023, S. e21617).

Neuere Studien zeigen, dass innovative Technologien und soziale Medien neue Einflussfaktoren auf die Kaufabsicht darstellen. Im Bereich des Influencer-Marketings gewinnen künstliche Intelligenz-basierte Influencer:innen zunehmend an Bedeutung. Forschungsergebnisse belegen, dass Faktoren wie die wahrgenommene Glaubwürdigkeit, informative Inhalte und menschliche Ähnlichkeit von KI-Influencern maßgeblich das Engagement von Konsument:innen und deren Kaufabsicht beeinflussen. Besonders die informative Qualität und die wahrgenommene Vertrauenswürdigkeit von AI-Influencer:innen wirken sich positiv auf die Absicht aus, ein beworbenes Produkt zu erwerben. Gleichzeitig zeigt sich, dass Aspekte wie Attraktivität und Unterhaltungswert vor allem das Engagement, jedoch nicht unmittelbar die Kaufintention fördern (Jayasingh, Sivakumar & Vanathaiyan, 2025, S. 1).

Neben künstlicher Intelligenz gewinnt auch die Nutzung sozialer Netzwerke für den Kaufentscheidungsprozess an Relevanz. Der Kontakt mit Werbeinhalten auf Plattformen wie WhatsApp wirkt sich signifikant auf die wahrgenommene Glaubwürdigkeit von

Produktempfehlungen aus, die wiederum einen direkten Einfluss auf die Kaufabsicht ausübt. Hierbei verstärken soziale Bindungen, insbesondere starke und hierarchische Verbindungen, den positiven Effekt der Werbeexposition auf die Glaubwürdigkeit und tragen so zu einer erhöhten Kaufabsicht bei (Nyazabe, Lee & Vololoniaina, 2025, S. 1). Die Ergebnisse deuten darauf hin, dass Vertrauen, welches innerhalb privater sozialer Netzwerke aufgebaut wird, eine zentrale Rolle bei der Steuerung von Kaufentscheidungen spielt.

Darüber hinaus hat sich Augmented Reality (AR) als effektives Mittel im E-Commerce etabliert, um die Kaufabsicht von Konsument:innen zu steigern. AR-Anwendungen verbessern die wahrgenommene Nützlichkeit und machen das Einkaufserlebnis emotionaler und angenehmer, indem sie interaktive und lebendige Produktdarstellungen ermöglichen. Besonders die wahrgenommene Lebendigkeit und der Informationsgehalt von AR-Angeboten beeinflussen die positiven Einstellungen der Konsument:innen und tragen entscheidend zur Kaufintention bei. Nutzer:innen erleben AR-gestützte Shoppingumgebungen als unterhaltsam und nützlich, was ihre Zufriedenheit und ihre Bereitschaft zu einem Kauf erhöht (Ngo, Tran, An & Nguyen, 2025, S. 100648).

2.2.6 Zusammenfassung der Modelle

Folgende Tabelle präsentiert noch einen Überblick und Zusammenfassung der theoretischen Modelle:

Tabelle 1

Zusammenfassung der Modelle

Text	Text
Theory of Planned Behaviour (TPB)	Die TPB erklärt Verhalten durch Intention, die von Einstellung, subjektiver Norm und wahrgenommener Verhaltenskontrolle beeinflusst wird.
Elaboration Likelihood Model (ELM)	Das ELM beschreibt zwei Wege der Einstellungsänderung, nämlich den zentralen mit kognitiver Verarbeitung und den peripheren mit oberflächlichen Hinweisreizen.
Technology Acceptance Model (TAM)	Die Akzeptanz von Technologien wird maßgeblich durch die wahrgenommene Nützlichkeit und Benutzerfreundlichkeit beeinflusst.
Attitude Toward the Ad (ATTA)	Die Einstellung gegenüber einer Werbeanzeige beeinflusst die Markenbewertung und Kaufabsicht sowohl direkt als auch indirekt über die Wahrnehmung von Markeninformationen.
Purchase Intention (PI)	Die Kaufabsicht beschreibt die Wahrscheinlichkeit eines Kaufs und wird von persönlichen, kognitiven und externen Faktoren wie Markenimage und Vertrauen beeinflusst.

2.3 Künstliche Intelligenz

Künstliche Intelligenz (KI), im englischen „Artificial Intelligence“ (AI) hat seit ihrer Einführung eine Vielzahl von Definitionen erfahren, die ihre Komplexität und Vielschichtigkeit widerspiegeln. John McCarthy prägte den Begriff 1956 und definierte KI als „die Wissenschaft und Technik, intelligente Maschinen zu bauen“ (McCarthy, Minsky, Rochester & Shannon, 1955, S. 1). Seither wurde der Begriff stetig weiterentwickelt, um den technologischen Fortschritt und die Erweiterung der Anwendungsbereiche widerzuspiegeln. Eine verbreitete Definition beschreibt KI als Systeme, die in der Lage sind, kognitive Funktionen wie Wahrnehmen, Lernen, Problemlösen und Interaktion auszuführen, Fähigkeiten, die traditionell mit menschlichem Denken assoziiert werden. Trotz zahlreicher Fortschritte gibt es bis heute keine einheitliche Definition, was Intelligenz in Bezug auf Maschinen ausmacht. Einige Forscher argumentieren, dass Intelligenz von Maschinen anders betrachtet werden sollte als menschliche Intelligenz, da sie nicht denselben evolutionären und biologischen Einschränkungen unterliegt (Collins et al., 2021, S. 102383).

Ein Überblick über die Entwicklung und den Einsatz von KI zeigt, dass das Interesse an diesem Thema in den letzten Jahren stark zugenommen hat. Seit 2010 sind Fortschritte

in maschinellem Lernen, neuronalen Netzwerken und anderen KI-Technologien entscheidend für die breitere Anwendung in Bereichen wie Gesundheitswesen, Fertigung und digitalem Marketing. Laut der Analyse der Primärstudien in der Informationssystemforschung stieg die Anzahl der KI-bezogenen Publikationen insbesondere zwischen 2019 und 2020 signifikant an, was auf eine zunehmende Bedeutung des Themas hindeutet. Diese Entwicklung wird auch durch technologische Innovationen unterstützt, die KI-Systeme leistungsfähiger und zugänglicher machen, wie die Einführung spezialisierter Hardware und die Verfügbarkeit großer, annotierter Datenmengen (Collins et al., 2021, S. 102383). Die folgende Abbildung zeigt den Anstieg an wissenschaftliche Publikationen von 1984 bis 2022, die sich auf KI-Adaption fokussieren:




Abbildung 4: Entwicklung der jährlichen Anzahl von Veröffentlichungen zur KI-Adoption zwischen 1984 und 2022 (Khanfar, Kiani Mavi, Iranmanesh & Gengatharen, 2024, S. 10).

Abbildung 3 zeigt einen markanten Anstieg der wissenschaftlichen Veröffentlichungen zur KI-Adoption ab dem Jahr 2020, was auf das wachsende Interesse von Forschung und Praxis an den Potenzialen künstlicher Intelligenz hinweist. Die Studie führt diesen Anstieg auf die zunehmende Relevanz von KI-Systemen zur Optimierung von Entscheidungsprozessen, Automatisierung routinemäßiger Aufgaben und zur Bewältigung großer Datenmengen zurück. Zudem betonen die Autoren, dass die steigenden Investitionen und der Wettbewerbsdruck Unternehmen dazu drängen, KI als strategisches Werkzeug zu implementieren (Khanfar et al., 2024, S. 10ff).

2.3.1 Maschinelles Lernen

Maschinelles Lernen ist ein zentraler Bereich der Künstlichen Intelligenz, der darauf abzielt, Systeme zu entwickeln, die durch Analyse von Daten eigenständig lernen können. Im Supervised Learning erfolgt dies anhand gelabelter Daten, die als Grundlage für präzise Vorhersagen dienen. Beim Unsupervised Learning hingegen werden Muster in unstrukturierten Daten erkannt, beispielsweise durch Clustering, eine Technik, die

Datenpunkte auf Basis ihrer Ähnlichkeiten in Gruppen unterteilt, um verborgene Strukturen zu identifizieren. Eine weitere Methode, das Reinforcement Learning, erlaubt es sogenannten Agenten, eigenständigen Software-Entitäten, durch Interaktion mit ihrer Umgebung Strategien zur Maximierung von Belohnungen zu entwickeln. Diese Agenten handeln dabei autonom, treffen Entscheidungen basierend auf vorherigen Erfahrungen und können durch kontinuierliches Lernen ihre Leistung verbessern. Die Ansätze finden breite Anwendung: im Gesundheitswesen bei der Diagnose von Krankheiten oder in der personalisierten Medizin, im Finanzwesen zur Betrugserkennung oder im algorithmischen Handel, sowie in Bildung, Transport und E-Commerce, etwa durch adaptive Lernsysteme, autonome Fahrzeuge oder Produktempfehlungen (Sheena Angra & Ahuja, 2017, S. 57; Shinde & Shah, 2018, S. 1).

Die Vorteile des maschinellen Lernens sind vielfältig. Es ermöglicht eine effizientere Entscheidungsfindung, die Automatisierung komplexer Prozesse und eine schnellere Verarbeitung großer Datenmengen im Vergleich zu traditionellen Methoden. Insbesondere Clustering im Rahmen von Unsupervised Learning bietet erhebliche Vorteile bei der Analyse unstrukturierter Daten, etwa bei der Segmentierung von Kundengruppen oder der Entdeckung neuer Muster in wissenschaftlichen Datensätzen. Die autonomen Entscheidungen von Agenten im Reinforcement Learning sind dabei besonders nützlich in Szenarien wie der Optimierung von Lieferketten oder der Steuerung autonomer Systeme. Dennoch stehen diese Systeme vor Herausforderungen. Insbesondere die Qualität und Quantität der Daten, auf denen sie beruhen, spielen eine entscheidende Rolle für die Leistungsfähigkeit der Modelle. Zudem erfordert die Interpretierbarkeit vieler Modelle, insbesondere bei komplexeren Ansätzen wie Deep Learning, um die Entscheidungsprozesse transparenter und besser nachvollziehbar zu gestalten (Sheena Angra & Ahuja, 2017, S. 57; Shinde & Shah, 2018, S. 1).

Mit dem rasanten Fortschritt im Bereich des maschinellen Lernens eröffnet sich ein breites Spektrum an Potenzialen für die Zukunft. Die Integration dieser Technologien in Alltags- und Industriebereiche wird nicht nur innovative Lösungen fördern, sondern auch neue ethische und regulatorische Fragen aufwerfen, etwa im Hinblick auf die verantwortungsvolle Nutzung von Daten oder die Reduktion von Verzerrungen in den Modellen. Diese Aspekte müssen parallel zur technologischen Entwicklung adressiert werden, um langfristige Vorteile für die Gesellschaft sicherzustellen (Sheena Angra & Ahuja, 2017, S. 57).

Ein grundlegendes Verständnis zentraler Konzepte wie des Feature Engineerings, bei dem wichtige Merkmale aus Daten ausgewählt und vorbereitet werden, ist wichtig, um die Leistungsfähigkeit maschineller Lernverfahren beurteilen zu können. Je nach

Komplexität der Daten und Zielstellung kommen verschiedene Modellarten zur Anwendung, wobei Entscheidungsbäume, neuronale Netze oder Random Forests jeweils spezifische Stärken hinsichtlich Genauigkeit und Interpretierbarkeit aufweisen (Janiesch, Zschech & Heinrich, 2021, S. 687). Im Bereich des Unsupervised Learning ermöglichen Clustering-Methoden wie k-Means die Identifikation verborgener Datenstrukturen, indem sie Datenpunkte auf Basis ihrer Ähnlichkeit gruppieren (2017, S. 58). Reinforcement Learning wiederum beruht auf einem lernbasierten Ansatz, bei dem Agenten durch Interaktion mit ihrer Umgebung schrittweise Strategien entwickeln, die langfristig optimale Ergebnisse erzielen, wobei sie ständig zwischen der Anwendung bewährter und der Erprobung neuer Handlungsoptionen abwägen (Sutton & Barto, 2018, S. 10). In diesem Zusammenhang gewinnen auch Methoden der erklärbaren künstlichen Intelligenz zunehmend an Bedeutung, da sie darauf abzielen, Entscheidungsprozesse komplexer Modelle transparenter und für Anwender:innen nachvollziehbar zu machen (Doshi-Velez & Kim, 2017, S. 2).

2.3.2 Big Data und Analytics

In der heutigen digitalen Welt nimmt die Bedeutung von Daten exponentiell zu. Mit der zunehmenden Verbreitung von Internetanwendungen, sozialen Netzwerken, mobilen Endgeräten und dem Internet der Dinge (IoT) werden täglich enorme Datenmengen generiert. Das IoT ist ein globales Netzwerk intelligenter, miteinander verbundener Geräte und Systeme, die über das Internet kommunizieren, Daten austauschen und autonom agieren können, wobei große Mengen an Daten generiert werden, die ideal für Big-Data-Analysen sind (Dudhe, Kadam, Hushangabade & Deshmukh, 2017, S. 2650).

Der Begriff "Big Data" beschreibt diese großen, komplexen und vielfältigen Datenmengen, die mit traditionellen Methoden der Datenverarbeitung nicht effizient analysiert werden können. Big Data umfasst strukturierte, semi-strukturierte und unstrukturierte Daten und wird von Technologien wie Cloud Computing und IoT maßgeblich beeinflusst (Mahmoudian et al., 2023, S. 554). In den vergangenen Jahren hat sich das Datenvolumen in nahezu allen Anwendungsbereichen exponentiell vergrößert, was zur Entstehung der sogenannten Big-Data-Ära geführt hat (Rawat, Doku & Garuba, 2021, S. 2055).

Die folgende Abbildung zeigt verschiedene Beispiele für den exponentiellen Wachstum von Daten:




Abbildung 5: Beispiele für den exponentiellen Wachstum von Daten (Rawat et al., 2021, S. 2056).

Big Data wird oft durch das 4V-Modell beschrieben: Volume (Volumen), Velocity (Geschwindigkeit), Variety (Vielfalt) und Veracity (Wahrhaftigkeit). Das Volumen bezieht sich auf die riesigen Datenmengen, die von Terabytes bis zu Zettabytes reichen. Velocity beschreibt die Geschwindigkeit, mit der Daten erzeugt und verarbeitet werden, oft in Echtzeit. Variety steht für die Vielfalt der Datenformate, von strukturierten Datenbanken bis hin zu unstrukturierten Formaten wie Bildern oder Videos. Veracity bezieht sich auf die Vertrauenswürdigkeit und Qualität der Daten. Ergänzend wird häufig der Wert (Value) betont, der den potenziellen Nutzen beschreibt, der aus der Analyse von Big Data gewonnen werden kann (Mahmoudian et al., 2023, S. 554). Die folgende Abbildung zeigt das Zusammenspiel der einzelnen Bestandteile des 4V-Modells und wie diese Bestandteile für Unternehmen nützlich sein können:




Abbildung 6: Darstellung des 4V-Modells und der zentraler Nutzen von Big Data für Unternehmen (Rawat et al., 2021, S. 2056).

Die Analyse von Big Data bietet attraktive und wertvolle Möglichkeiten. Dennoch stehen Forschende und Fachleute in diesem Bereich vor zahlreichen Herausforderungen, wenn es darum geht, Big Data zu erkunden und Wissen sowie Mehrwert daraus zu gewinnen. Diese Probleme treten auf verschiedenen Ebenen auf, darunter Datenspeicherung, Datenvisualisierung, Analyse, Lebenszyklusmanagement, Reduzierung von Redundanz und Datenkompression. Darüber hinaus stellen Fragen des Datenschutzes und der Vertraulichkeit erhebliche Hürden dar, die insbesondere in verteilten Anwendungen von Big Data überwunden werden müssen (Mahmoudian et al., 2023, S. 555).

Die Anwendungsbereiche von Big Data sind vielfältig: von der Betrugserkennung über die Optimierung des Kundenservice bis hin zur Analyse von sozialen Netzwerken und der Vorhersage von Finanzmarkttrends. Trotz dieser Vorteile bringt Big Data auch Herausforderungen mit sich, wie die effiziente Speicherung großer Datenmengen, die Verarbeitung unstrukturierter Daten, den Schutz sensibler Informationen und den hohen Energiebedarf von Rechenzentren (Mahmoudian et al., 2023, S. 555).

Big Data ist von entscheidender Bedeutung für die Entwicklung und Leistungsfähigkeit von KI, da KI auf große Datenmengen angewiesen ist, um Muster zu erkennen, aus

Erfahrungen zu lernen und präzise Vorhersagen zu treffen. Ohne die Verfügbarkeit umfangreicher und vielfältiger Datensätze wäre es für KI-Modelle unmöglich, die Komplexität realer Szenarien zu verstehen und fundierte Entscheidungen zu treffen. Big Data liefert nicht nur die notwendigen Trainingsdaten für maschinelles Lernen, sondern ermöglicht auch die kontinuierliche Optimierung von KI-Systemen, da diese aus neuen Daten immer wieder dazulernen können. Gleichzeitig hilft KI dabei, die enormen Datenmengen effizient zu verarbeiten, indem sie Automatisierungsprozesse übernimmt, Anomalien erkennt und tiefere Einblicke in komplexe Zusammenhänge liefert, die für den Menschen schwer zugänglich wären (Demigha, 2020, S. 1395).

3 KI-gestützter Personalisierung in Online-Werbeanzeigen

In diesem Kapitel werden konkrete Anwendungsbereiche der Künstlichen Intelligenz im Kontext der personalisierten Online-Werbung dargestellt.

3.1 Personalisierung von Inhalten durch KI

Die Personalisierung von Inhalten stellt eine der zentralen Anwendungen Künstlicher Intelligenz im digitalen Marketing dar. Durch den Einsatz maschinellen Lernverfahren werden Nutzerverhalten, Interaktionen und Präferenzen analysiert, um Inhalte passgenau auf einzelne Individuen zuzuschneiden.

Ein Beispiel für eine aktuelle wissenschaftliche Arbeit zur Personalisierung von Inhalten ist die Entwicklung von TranSlider, einem interaktiven KI-gestützten Tool zur Übersetzung wissenschaftlicher Texte für Laien (Kim, Agarwal, Ackerman & Saha, 2024, S. 4ff). Folgende Abbildung zeigt das Tool:

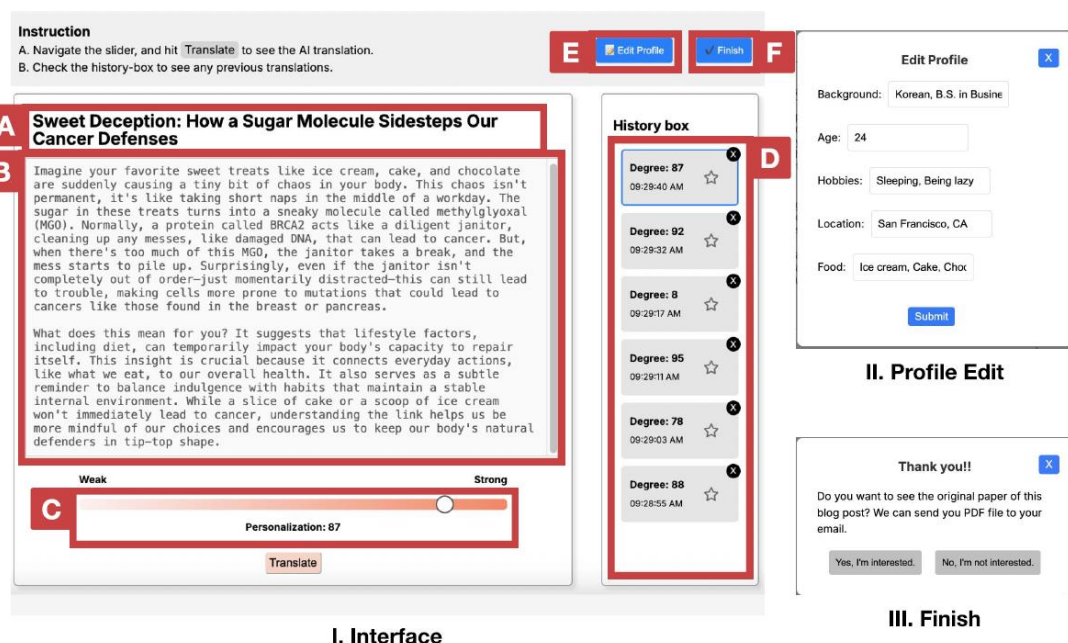


Abbildung 7: Das Interface von TranSlider (Kim et al., 2024, S. 5).

Dabei werden mithilfe großer Sprachmodelle personalisierte Analogien erzeugt, die an das individuelle Profil der Nutzenden angepasst sind und über einen Schieberegler in ihrer Intensität steuerbar sind. Eine explorative Studie zeigt, dass verschiedene Personalisierungsgrade unterschiedliche Bedürfnisse bedienen, während einige Teilnehmer:innen stark personalisierte und kontextreiche Übersetzungen bevorzugten,

schätzten andere kürzere, sachlichere Varianten mit subtilen Anpassungen (Kim et al., 2024, S. 4ff).

Eine weitere Arbeit von Gao und Liu befasst sich mit KI-gestützter Personalisierung im interaktiven Marketing entlang der gesamten Customer Journey. Es zeigt, wie personalisierte Profilbildung, Navigation, Kaufanreize und Kundenbindung durch den Einsatz von KI gestaltet werden, und diskutiert dabei auch die damit verbundenen Herausforderungen wie Missverständnisse durch fehlerhafte Profilierungen, intransparente Preissetzungen oder übergriffige Chatbots. Abschließend entwirft die Studie einen Forschungsfahrplan, der unter anderem den Einfluss von kulturellen Kontexten, Datenschutzfragen und der Integration von Service-Robotern in personalisierte Kundenerlebnisse thematisiert (Gao & Liu, 2022b, S. 1ff).

Trawnih et al. untersuchen in ihrer Studie, wie die Integration von KI das Kundenerlebnis beim Online-Shopping verändert und entwickeln dafür ein Modell, das auf der Servicequalitäts- sowie der Vertrauens- und Bindungstheorie basiert (Trawnih, al masaeed, Alsoud & Alkufahy, 2022, S. 1471ff). Die folgende Abbildung zeigt ihr KI-gesteuertes Customer-Experience-Model:




Abbildung 8: Das KI-gesteuerte Customer-Experience-Model (Trawnih et al., 2022, S. 1476).

Ihre Ergebnisse zeigen, dass Vertrauen und wahrgenommene Opferbereitschaft zentrale Vermittlungsgrößen darstellen, die den Einfluss von Personalisierung, Komfort und Servicequalität auf das KI-gestützte Kundenerlebnis maßgeblich prägen. Besonders hervorgehoben wird die Bedeutung der Beziehungstreue zur Marke, die langfristig die positive Wahrnehmung von KI-basierten Services stärkt (Trawnih et al., 2022, S. 1471ff).

3.2 Personalisierte Onlinewerbeschaltungen durch KI

Neben der inhaltlichen Personalisierung spielt die KI auch eine entscheidende Rolle bei der automatisierten Schaltung von Onlinewerbung.

Masnita et al. analysieren in ihrer systematischen Literaturübersicht die vielfältigen Einsatzmöglichkeiten Künstlicher Intelligenz im Marketing und zeigen auf, wie Unternehmen durch Automatisierung, Datenanalyse und Personalisierung ihre Marketingeffektivität steigern können. Die Untersuchung gliedert relevante Forschungsbeiträge in thematische Cluster, darunter Vertrauen im Kundenkontakt, datengetriebene Entscheidungsfindung, Konsumentenverhalten sowie den Einfluss von Emotionen und Künstlicher Intelligenz auf die Kundenbindung. Abschließend leiten die Autorinnen und Autoren zukünftige Forschungsperspektiven ab, etwa zur Rolle von KI im Non-Service-Sektor, zur Verbindung mit Data-Mining-Strategien oder zur Wirkung auf Kundenloyalität und Empfehlungsverhalten (Masnita, Kasuma, Zahra, Wilson & Murwonugroho, 2024, S. 120ff).

Hendrayati et al. untersuchen in ihrer quantitativen Studie, wie Unternehmen in Indonesien Künstliche Intelligenz in ihre digitalen Marketingstrategien integrieren, um ihre Wettbewerbsfähigkeit zu steigern. Die Ergebnisse zeigen, dass KI-Anwendungen wie Chatbots, prädiktive Analysen und Empfehlungssysteme zu einer deutlichen Steigerung von Kundeninteraktionen, Konversionsraten und operativer Effizienz führen. Besonders betont wird, dass die Nutzung von KI nicht nur großen Unternehmen, sondern auch kleinen und mittleren Betrieben zugutekommt, da sie mit begrenzten Ressourcen effizienter arbeiten und personalisierte Kundenerlebnisse schaffen können (Hendrayati, Achyarsyah, Marimon, Hartono & Putit, 2024, S. 2343ff).

3.3 KI in der Marketingforschung

Auch in der wissenschaftlichen Marketingforschung findet der Einsatz Künstlicher Intelligenz zunehmend Verbreitung.

Verma et al. führen in ihrer systematischen Literaturübersicht eine umfassende bibliometrische Analyse zu Künstlicher Intelligenz im Marketing durch und werten über 1500 wissenschaftliche Beiträge aus, um zentrale Forschungsthemen, relevante Akteure und künftige Forschungsperspektiven zu identifizieren (Verma, Sharma, Deb & Maitra, 2021, S. 1ff). Die folgende Abbildung zeigt die visuelle Darstellung der Netzwerkanalyse der unterschiedlichen wissenschaftlichen Arbeiten im Marketingbereich:





Abbildung 9: Visuelle Darstellung des Netzwerkes von wissenschaftlichen Arbeiten in Marketing (Verma et al., 2021, S. 5).

Dabei zeigen sie, dass KI in zahlreichen Bereichen wie Kundenbindung, Produkt- und Preismanagement, Vertriebsoptimierung und personalisierter Kommunikation erfolgreich eingesetzt wird. Als zentrale zukünftige Forschungsrichtungen nennen sie unter anderem die Integration psychologischer Modelle, semantischer Analysen und emotionaler KI zur Vertiefung des Kundenverständnisses und zur Weiterentwicklung intelligenter, datenbasierter Marketingstrategien (Verma et al., 2021, S. 1ff).

Dzyabura und Hauser präsentieren ein aktives Lernverfahren, das darauf abzielt, die heuristischen Entscheidungsregeln von Konsument:innen bei der Fahrzeugauswahl effizient zu identifizieren. Durch intelligente Abfragealgorithmen wird der Informationsgewinn pro Konsumenteninteraktion maximiert, was insbesondere bei der Personalisierung von Marketingbotschaften, Produktempfehlungen oder Angebotsgestaltungen von hoher Relevanz ist (Dzyabura & Hauser, 2009, S. 30ff). Die folgende Abbildung zeigt eine Beispielabfrage mit Konfiguration, das die Konsument:innen sehen:




The screenshot shows a car configuration interface. At the top, there is a small image of a gold minivan. Below it, a table lists the following attributes:

Body Type	Minivan
Price	\$32,000
Engine Type	Gasoline
Composite MPG	20
Brand	Toyota
Engine Cylinders	6
Quality Rating	★★★★☆
Crash Test Rating	★★★★☆

Below the table, there are two radio buttons: "Consider" (selected) and "Would Not Consider". At the bottom, it says "29 questions left" and has a "Next >>" button.

(a) Example Query



The screenshot shows a car configuration interface. At the top, there is a small image of a gold sports car. Below it, there are several dropdown menus for configuration:

- Body Type: [Dropdown menu] [Down arrow]
- Brand: [Dropdown menu]
- Engine Cylinders: [Dropdown menu]
- Composite MPG: [Dropdown menu]
- Engine Type: [Dropdown menu]
- Price: [Dropdown menu]

At the bottom, there is a "Consider" button.

(b) Example Configurator

Abbildung 10: Beispielabfrage von Autos mit Konfigurationen (Dzyabura & Hauser, 2009, S. 38).

Die empirische Anwendung im Automobilbereich zeigt, dass dieses Verfahren mit deutlich weniger Interaktionen vergleichbare oder bessere Vorhersageleistungen als klassische Designs erzielt und somit neue Möglichkeiten für individualisierte, ressourcenschonende Marketingstrategien eröffnet (Dzyabura & Hauser, 2009, S. 30ff).

3.4 Einsatz von KI im Marketing und Datenschutz

Die zunehmende Nutzung Künstlicher Intelligenz im Marketing wirft zugleich eine Reihe datenschutzrechtlicher und ethischer Fragestellungen auf.

Saura et al. untersuchen in ihrer systematischen Analyse die ethischen Herausforderungen KI-gestützter Marketingstrategien mit besonderem Fokus auf Datenschutz und zeigen dabei ein neues „Privacy Paradox“ auf. Obwohl personalisierte Werbung, verhaltensbasierte Analysen und smarte Inhalte die Effizienz im digitalen Marketing erhöhen, geschieht dies oft auf Kosten der Nutzertransparenz und -autonomie, da viele Daten ohne bewusstes Einverständnis gesammelt werden. Die Studie betont die Notwendigkeit eines ethisch fundierten Frameworks, das Datenschutz als Ausdruck persönlicher Identität versteht und ruft zu Marketingpraktiken auf, die mit Prinzipien wie „Privacy by Design“ und „Data Dignity“ vereinbar sind (Saura, Škare & Ozretić Došen, 2024, S. 9ff).

Alhitmi et al. analysieren in ihrer systematischen Literaturstudie die Herausforderungen, die mit der Nutzung Künstlicher Intelligenz im Marketing im Hinblick auf Datenschutz und Datensicherheit einhergehen. Die Autor:innen zeigen, dass insbesondere Cyberangriffe, Falschinformationen und unautorisierte Datenweitergabe das Vertrauen der Kundschaft untergraben und damit die Effektivität KI-gestützter Marketingstrategien gefährden. Als Lösungsansätze diskutieren sie unter anderem Datenschutzversicherungen, technologische Reifegrade wie RFID, Managementunterstützung sowie politische Rahmenbedingungen, die gemeinsam einen verantwortungsvollen und wirtschaftlich tragfähigen Umgang mit sensiblen Daten ermöglichen sollen (Alhitmi, Mardiah, Al-Sulaiti & Abbas, 2024, S. 11ff).

Mühlhof führt mit dem Konzept der Predictive Privacy eine ethisch fundierte Perspektive auf den Einsatz von Predictive Analytics im datengetriebenen Marketing ein, die über klassische Datenschutzansätze hinausgeht (Mühlhoff, 2021, S. 675ff). Folgende Abbildung veranschaulicht, wie das „Predictive Model“ aus unsensiblen Informationen und anonymen Datenspuren sensible Informationen geniert werden:




Abbildung 11: Visualisierung des „Predictive Model“, das sensible Informationen generiert (Mühlhoff, 2021, S. 678).

Er kritisiert, dass KI-Systeme sensible Informationen über Individuen auf Basis von Daten vieler anderer Nutzer:innen vorhersagen, ohne dass diese sich dessen bewusst sind, und zeigt auf, wie daraus differenzierende Entscheidungen mit realen Auswirkungen entstehen. Für das Marketing bedeutet dies eine zentrale ethische Herausforderung, da personalisierte Maßnahmen zwar effizient sind, aber nur dann legitim, wenn sie die informationelle Selbstbestimmung wahren und kollektive Verantwortung im Umgang mit Nutzerdaten übernehmen (Mühlhoff, 2021, S. 675ff).

Mühlhoff et al. analysieren, wie datengetriebenes Targeting in sozialen Medien, etwa bei der Rekrutierung für klinische Studien, fundamentale Herausforderungen für das datenethisch verantwortungsvolle Marketing aufwirft. Sie zeigen, dass KI-basierte Werbestrategien zwar Effizienz versprechen, dabei jedoch hochsensible medizinische Informationen über Nutzer:innen prädiktiv erschließen und kommerziell verwerten. Oft geschieht das ohne Zustimmung der Nutzer:innen. Hier ist ein Beispiel für ein Upload von Dateien, wo bestimmte Attribute ausgewählt werden können (Mühlhoff & Willem, 2023, S. 10ff):

Create a Custom Audience [X]

1 Add Customer List 2 Edit Data Mapping 3 Hashed Upload & Creation 4 Next Steps

Prepare a file with your customer data
[How to prepare your data](#)

Identifiers you can use (15) ⓘ

Email Phone Number Mobile Advertiser ID First Name Last Name ZIP/Postal Code City
 State/Province Country Date of Birth Year of Birth Gender Age Facebook App User ID
 Facebook Page User ID

☒ Add a new file (CSV or TXT) [Download file template](#)

Drag and drop your file here or

☐ Copy and paste

☒ I agree to the [Facebook Custom Audiences Terms](#)

Audience name 50 [Show description](#)

Abbildung 12: Oberfläche zum Hochladen von Kundendateien (Mühlhoff & Willem, 2023, S. 6).

Besonders kritisch ist dabei, dass diese Praktiken kollektive Datenschutzrisiken erzeugen, die durch bestehende Regulierungen nicht ausreichend adressiert werden und langfristig diskriminierende Effekte für vulnerable Zielgruppen im digitalen Marketing nach sich ziehen können (Mühlhoff & Willem, 2023, S. 10ff).

4 Empirische Untersuchung

Dieses Kapitel beschreibt die empirische Untersuchung und dient dazu, den Aufbau der quantitativen Forschung zu beschreiben. Der Aufbau umfasst die Forschungsfrage und den Hypothesen, die Erläuterung der quantitativen Forschung und die Analyse und Auswertung der Daten.

4.1 Forschungsfrage und Hypothese

Die bereits erwähnten Studien und Theorien bieten bereits viele wichtige Erkenntnisse. Trotz der Fortschritte in vielen Bereichen gibt es mehrere unerforschte oder unzureichend erforschte Bereiche. Folgende Bereiche sind unzureichend untersucht:

- **Langzeitwirkung von personalisierten Anzeigen:** Während viele Studien kurzfristige Effekte untersuchen, fehlen umfassende Untersuchungen zur langfristigen Wirkung auf Kundenzufriedenheit und Markentreue.
- **Ethik und Privatsphäre:** Die Balance zwischen nützlicher Personalisierung und dem Gefühl der Überwachung durch Konsument:innen ist ein weitgehend unerforschter Bereich.
- **Unterschiedliche Zielgruppen:** Es gibt eine Lücke in der Forschung zu den Auswirkungen von Personalisierung auf verschiedene demografische Gruppen und Kulturen.

Die wissenschaftliche Debatte über die Wirksamkeit und Akzeptanz von KI-gestützter Personalisierung ist uneinheitlich. Während einige Forscher:innen, darunter Lambrecht und Tucker, die positiven Effekte hervorheben, warnen andere vor möglichen negativen Folgen, wie etwa einem Gefühl der Manipulation oder Überwachung (Lambrecht & Tucker, 2013, S. 50ff). Malhotra et al. argumentieren beispielsweise, dass eine zu starke Personalisierung als aufdringlich wahrgenommen werden und ablehnende Reaktionen hervorrufen kann (Malhotra, Kim & Agarwal, 2004, S. 15ff).

In dieser Arbeit wird die These vertreten, dass durch KI-unterstützte Personalisierung das Kaufverhalten sowie die Zufriedenheit der Konsument:innen steigert, sofern sie auf ethische und transparente Weise angewendet wird. Es wird davon ausgegangen, dass die Vorteile der Personalisierung, insbesondere ein verbessertes Kundenerlebnis und eine höhere Relevanz der Angebote, die potenziellen Nachteile überwiegen, sofern Datenschutzaspekte angemessen berücksichtigt werden.

Die zentrale Forschungsfrage lautet: "Welche Auswirkungen hat die Nutzung von KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Kaufverhalten der Konsument:innen?" Diese Fragestellung ist präzise formuliert und ermöglicht eine klare Eingrenzung des Untersuchungsfeldes. Sie stützt sich sowohl auf theoretische Modelle als auch auf empirische Studien.

Zur Beantwortung der Forschungsfrage werden folgende Hypothesen formuliert, die sowohl theoretisch als auch empirisch begründet sind:

- **H1:** „KI-gestützte personalisierte Werbung erhöht die Kaufbereitschaft der Konsument:innen im Vergleich zu nicht personalisierter Werbung.“
- **H2:** „Bei bestehender Privatsphäre wird KI-gestützte personalisierte Werbung seitens der Konsument:innen positiver bewertet.“
- **H3:** „Das Gefühl der Überwachung durch personalisierte Werbung kann die Bewertung der Konsument:innen negativ beeinflussen, unabhängig von der Werberelevanz.“
- **H4:** „Konsument:innen mit hohem Bewusstsein für Datenschutz reagieren weniger positiv auf KI-gestützte personalisierte Werbung im Vergleich zu Konsument:innen mit einem geringen Bewusstsein für Datenschutz. Dadurch weisen Konsument:innen mit einem hohen Bewusstsein eine geringere Kaufbereitschaft als auch eine geringere Zufriedenheit mit KI-gestützte personalisierte Werbung auf.“
- **H5:** „Die Effektivität von KI-gestützter personalisierter Werbung ist stärker ausgeprägt bei Konsument:innen, die bereits vorher positive Erfahrungen mit ähnlichen Werbemaßnahmen gemacht haben, im Vergleich zu Konsument:innen ohne solche Vorerfahrungen.“

Die erste Hypothese stützt sich auf mehrere theoretischen Modelle. Personalisierte, durch Künstliche Intelligenz generierte Werbung spricht individuelle Bedürfnisse und Interessen gezielt an, was ihre Relevanz für Konsumentinnen und Konsumenten erhöht (Boerman et al., 2021, S. 1). Nach dem ELM steigt dadurch die Wahrscheinlichkeit einer zentralen Informationsverarbeitung. Diese führt zu stabileren Einstellungen, die für das Verhalten relevant sind (Petty & Cacioppo, 1986, S. 5). Die TPB zeigt, dass positive Einstellungen gegenüber einem Verhalten wie dem Kauf eines Produkts die Verhaltensabsicht und letztlich das Verhalten stärken (Ajzen, 1991, S. 179). TAM betont die Rolle der wahrgenommenen Nützlichkeit für die Akzeptanz technologiebasierter Angebote wie KI-gestützter Werbung (Davis, 1989, S. 320; Zhao et al., 2023, S. e12600). Zusätzlich kann

eine positive Bewertung der Anzeige, wie sie im Attitude Toward the Ad-Modell beschrieben ist, die Kaufabsicht erhöhen (MacKenzie et al., 1986, S. 130).

Die zweite Hypothese basiert auf der Erkenntnis, dass das Empfinden von Privatsphäre und Kontrolle über persönliche Daten ein zentrales Element der Konsumentenwahrnehmung darstellt. Im Rahmen von TPB beeinflusst die wahrgenommene Verhaltenskontrolle das Verhalten maßgeblich, da sie den Grad widerspiegelt, in dem Individuen glauben, über Ressourcen und Möglichkeiten zur Handlungssteuerung zu verfügen (Ajzen, 1991, S. 179). Studien zeigen, dass der Schutz personenbezogener Daten die wahrgenommene Kontrolle stärkt und somit positive Einstellungen zur Werbung fördert (Bélanger & Crossler, 2011, S. 1017). Auch das Modell der ATTA hebt hervor, dass positive emotionale Reaktionen auf eine Anzeige, wie sie bei ausreichendem Datenschutz auftreten, die Werbewirkung begünstigen (MacKenzie et al., 1986, S. 130). Die aktuelle Forschung verdeutlicht zudem, dass die Wahrnehmung von Datenschutz nicht nur ein rechtlicher, sondern auch ein psychologisch wirksamer Faktor ist, der die Bewertung personalisierter Werbung beeinflusst (Mahmoudian et al., 2023, S. 490). Die Analyse des Privacy Paradox zeigt, dass Vertrauen durch Transparenz und Datenschutzrichtlinien positiv auf die Werbewahrnehmung wirkt (Saura et al., 2024, S. 9ff).

Die dritte Hypothese beleuchtet negative Effekte mangelnder Kontrolle über persönliche Daten. Wenn Konsument:innen nicht genügend kognitive Ressourcen aufbringen, können laut dem ELM Hinweisreize wie Misstrauen oder Unbehagen die Verarbeitung dominieren und eine zentrale Auseinandersetzung mit der Werbung verhindern (Gu et al., 2024, S. 2218; Petty & Cacioppo, 1986, S. 5). Die TPB zeigt, dass ein Gefühl der Ohnmacht gegenüber der eigenen Datenverarbeitung die positiven Einstellungen zum Verhalten schwächt (Ajzen, 1991, S. 179). Auch im ATTA-Modell können negative Emotionen aufgrund von Überwachung zu einer schlechten Bewertung der Anzeige führen, selbst wenn deren Inhalt als relevant wahrgenommen wird (MacKenzie et al., 1986, S. 130). Das Konzept der Predictive Privacy verdeutlicht, dass auch automatisierte Datenverarbeitung ohne explizite Zustimmung zu Vertrauensverlust und Ablehnung personalisierter Werbung führen kann (Mühlhoff, 2021, S. 675ff).

Die vierte Hypothese betrachtet Datenschutzsensibilität als individuellen Einflussfaktor. Personen mit stark ausgeprägtem Datenschutzbewusstsein zeigen laut TPB häufig kritischere Einstellungen gegenüber datenbasierter Werbung, da sie eine eingeschränkte Kontrolle und potenzielle Risiken wahrnehmen (Ajzen, 1991, S. 179; Bélanger & Crossler, 2011, S. 1017). TAM unterstreicht, dass fehlendes Vertrauen in die Nützlichkeit und Sicherheit einer Technologie bei diesen Personen zu geringerer Akzeptanz führt (Davis, 1989, S. 320; Zhang et al., 2024, S. 11273900). Negative emotionale Reaktionen auf

Eingriffe in die Privatsphäre beeinträchtigen laut dem ATTA-Modell die Bewertung der Anzeige und wirken sich negativ auf Zufriedenheit und Kaufabsicht aus (MacKenzie et al., 1986, S. 130).

Die letzte Hypothese bezieht sich auf die Wirkung positiver Erfahrungen und Vertrauen im Umgang mit KI-gestützter Werbung. TAM zeigt, dass solche Erfahrungen die wahrgenommene Nützlichkeit und Benutzerfreundlichkeit steigern und somit die Akzeptanz erhöhen (Davis, 1989, S. 320). Durch wiederholte positive Erlebnisse entwickelt sich Vertrauen, das die Offenheit für personalisierte Inhalte stärkt (Zhang & Zhao, 2023, S. e12600). Nach dem ELM steigt dadurch die Motivation zur zentralen Verarbeitung von Werbeinhalten (Petty & Cacioppo, 1986, S. 5). TPB ergänzt, dass sich durch positive Erfahrungen auch die Einstellungen zum Verhalten verbessern, was wiederum die Verhaltensintention erhöht (Ajzen, 1991, S. 179). Das ATTA-Modell betont abschließend, dass frühere positive Werbeerfahrungen die Anzeige günstiger bewerten lassen und so die Kaufabsicht fördern (MacKenzie et al., 1986, S. 1986; Wang et al., 2023, S. e21617).

4.2 Quantitative Forschung

Im folgenden Kapitel wird die quantitative Forschungsmethodik beschrieben, die auf der theoretischen Grundlage dieser Arbeit sowie den Forschungsfragen und Hypothesen basiert. Dabei steht das Fragebogendesign im Fokus.

4.2.1 Fragebogendesign

Die Umsetzung des Fragebogens in Qualtrics erfolgt unter Berücksichtigung der vorgegebenen Struktur, welche aus einer Einleitung, demografischen und persönlichen Fragen, Fragen zu den Produktgruppeninteressen, einer randomisierten Zuteilung in Experimental- oder Kontrollgruppe sowie spezifischen Fragen innerhalb dieser Gruppen besteht.

In der Einleitung wird den Teilnehmer:innen eine kurze Vorstellung der Studie präsentiert. Dabei werden das Ziel und der Zweck des Fragebogens erläutert, eine Einverständniserklärung eingeholt und rechtliche Aspekte wie die Anonymisierung der Daten sowie der Datenschutz berücksichtigt. Weiters erhalten die Proband:innen mit einer 50% Wahrscheinlichkeit ein Hinweistext angezeigt, um die Hypothese H3 zu untersuchen. Es wird hingewiesen, dass nicht-persönliche Daten im Rahmen der Umfrage gespeichert werden.

Anschließend werden persönliche, demografische Fragen gestellt, die das Alter, das Geschlecht und den Bildungsabschluss der Teilnehmer:innen abfragen (Ziegenfuss et al., 2021, S. 1ff). Ergänzend dazu werden individuelle Fragen zu den Shoppinginteressen,

dem Einkaufsverhalten und das Interesse über Online-Werbungen erhoben. Die Frage über das Shoppinginteresse ist vor allem für die Hypothese H5 relevant, welches das Interesse der Teilnehmer:innen miteinbezieht.

Im nächsten Abschnitt des Fragebogens werden die Teilnehmer:innen gebeten, anzugeben, welche Produktkategorien sie am meisten interessieren. Hierbei müssen die Teilnehmer:innen mindestens drei Kategorien auswählen. Die Antworten zu diesem Abschnitt sind ausschließlich für Experimentalgruppe relevant, die anhand der Auswahl zufällig im nächsten Abschnitt eine Produktwerbung erhalten. Jedoch finden sie in der weiteren Analyse für die Hypothesen keine direkte Anwendung. Folgende Produktkategorien stehen im Fragebogen zur Auswahl (Mazgaonkar & Mandhare, 2024, S. 25ff):

- Smartphones
- Laptops
- Smartwatches
- Lebensmittel & Getränke
- Kamera
- Film & Musik
- Tablets
- Kosmetik

Der nächste Teil im Fragebogen enthielt die Frage zur Besorgnis über die Privatsphäre im Internet, insbesondere in Bezug auf den Schutz persönlicher Daten. Die Proband:innen aus der Stichprobe werden gefragt, wie besorgt sie über den Schutz ihrer persönlichen Daten im Internet sind. Diese Frage ist sehr essenziell, da sie für die Messung der Hypothese H4 und H5 benötigt werden. Die Frage nach dem Schutz persönlicher Daten im Internet ist relevant zu messen, weil sie Aufschluss darüber gibt, wie Menschen ihre Privatsphäre wahrnehmen und welche Bedeutung sie dem Umgang mit ihren Informationen beimessen (Preibusch, 2013, S. 1133ff). Diese Frage ist für die Hypothese H2 relevant und dient dabei die Stichprobe in mehrere Gruppen basierend der fünf Ausprägungen als Antwortmöglichkeit für diese Hypothese zu unterteilen.

Die Zuteilung in die Experimental- oder Kontrollgruppe erfolgt randomisiert über Qualtrics, wobei die Proband:innen nicht darüber informiert werden, dass sie zufällig einer der beiden Gruppen zugewiesen wurden.

Alle Teilnehmer:innen der Kontrollgruppe erhalten eine identische Darstellung, der dieselben Produkte beinhaltet. Ihnen werden dieselbe Produktwerbungen in Form eines Bildes, exemplarisch durch ein Wasserfilter, präsentiert.

Im Anschluss werden sie hinsichtlich der Wirkung der Werbung befragt, wobei unter anderem ermittelt wird, wie gut die gezeigte Werbung zu ihren Interessen passt, wie ansprechend, wie wahrscheinlich das Produkt aus der Werbung erwerben möchten, wie vertrauenswürdig sie diese bewerten und ob sie Bedenken hinsichtlich der Erfassung ihrer Interessen durch die Werbung haben. Diese essenziellen Fragen werden für die Hypothesen H1, H2, H3, H4 und H5 verwendet. Weiters wird gefragt, wie wahrscheinlich die Proband:innen das beworbene Produkt erwerben möchten. Letztlich wird noch gefragt, ob sie sich Sorgen machen, dass die Werbung Ihre Interessen erkannt bzw. nicht erkannt haben.

Im nächsten Abschnitt beantworten die Teilnehmer:innen Fragen zu ihren Empfindungen hinsichtlich der Privatsphäre beim Betrachten der Werbung. Dabei wird erfasst, ob sie sich durch die Werbung überwacht fühlten, ob sie den Eindruck hatten, dass ihre persönlichen Daten ohne ihr Wissen für die Anzeige der Werbung verwendet wurden, sowie wie stark ihre generelle Besorgnis um den Datenschutz ausgeprägt ist. Diese Fragen sind für die Hypothesen H3 und H5 relevant.

Im Unterschied dazu erhalten die Proband:innen der Experimentalgruppe ein KI-generiertes Bild, das auf den zuvor ausgewählten Produktkategorien basiert. Für jede ausgewählte Produktkategorie wird eine spezifische KI-generierte Produktwerbung angezeigt, sodass auf Basis der Antworten zu den Produktkategorien eine gezielt aus dieser Kategorie stammende Produktwerbung präsentiert wird. Abschließend werden ihnen dieselben Fragen zur Wirkung der Werbung und die Privatsphäre gestellt, wie sie bereits der Kontrollgruppe vorgelegt wurden.

Das folgende Diagramm veranschaulicht noch einmal den Kontrollfluss im Fragebogen:




Abbildung 13: Kontrollfluss im Fragebogen.

Die folgende Tabelle bietet zusammenfassend einen Überblick darüber, welche Fragen welcher Hypothese zugeordnet sind:

Tabelle 2

Zuordnung der Fragen zu den jeweiligen Hypothesen

Frage	Zugeordnete Hypothesen
Wie interessiert sind Sie an Online-Werbung?	H5
Wie besorgt sind Sie über den Schutz Ihrer persönlichen Daten im Internet?	H2
Wie gut passt die gezeigte Werbung zu Ihren Interessen?	H1, H4, H5
Wie ansprechend finden Sie diese Werbung?	H1, H2, H3, H4, H5
Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?	H1, H2, H3
Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?	H3
Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden?	H5
Haben Sie das Gefühl, dass Ihre persönlichen Daten ohne Ihr Wissen für diese Werbung verwendet wurden?	H3
Wie sehr sind Sie über Datenschutz besorgt?	H4

4.3 Analyse und Auswertung

Im folgenden Kapitel wird der Prozess der Datenaufbereitung und der Vorbereitung der Analyse im Detail erläutert. Zunächst wird dargelegt, wie die erhobenen Daten strukturiert und bereinigt wurden, um eine valide und zuverlässige Grundlage für die anschließende Auswertung zu schaffen. Im Anschluss daran wird beschrieben, welche methodischen Schritte unternommen wurden, um die Analyse systematisch vorzubereiten. Abschließend widmet sich das Kapitel dem eigentlichen Auswertungsprozess.

4.3.1 Datenaufbereitung

Nach Abschluss der Datenerhebung wurden die Daten aus Qualtrics in einem strukturierten Tabellenformat exportiert und für die anschließende Analyse vorbereitet. Dabei wurde der Datensatz zunächst auf potenzielle Verzerrungen und Fehler geprüft sowie entsprechend bereinigt.

Bei der Erstellung in Qualtrics wurde der Fragebogen im Vorschaumodus getestet, um alle erwarteten Fragen und Verzweigungen zu testen. Teilweise war der Fragebogen noch nicht vollständig entwickelt und hatte fehlerhafte Antworten, wie zum Beispiel fehlerhafte Antworten, die in der fertigen Fragebogenversion nicht mehr enthalten waren. Die Testversuche sind auch Teil des Datensatzes, die zu Verzerrungen geführt haben. Weiters führen nicht vollständig beantwortete Fragebögen zu Verzerrungen, da einige Fragen nicht beantwortet werden. Dies kann die Validität der Ergebnisse beeinträchtigen, da unvollständige Daten die Repräsentativität der Stichprobe verringern und zu systematischen Fehlern in der Datenauswertung führen können. Zudem kann die Annahme verletzt werden, dass fehlende Werte zufällig sind, was die Generalisierbarkeit der Befunde einschränkt (Dong & Peng, 2013). Testversuche haben den Wert „preview“, die in der Spalte „DistributionChannel“ gespeichert werden.

Als weiteres zentrales Kriterium für die Aufnahme in die Auswertung galt, dass ein Fragebogen vollständig ausgefüllt sein musste. Vollständig bedeutet in diesem Zusammenhang, dass alle Fragen bis einschließlich derjenigen zur Wirkung der Werbung sowie zum subjektiven Eindruck hinsichtlich der Privatsphäre beantwortet wurden. In Qualtrics-Datensatz gibt es eine Spalte, die beschreibt, ob eine Umfrage komplett abgeschlossen wurde bzw. die letzte Frage nicht beantwortet wurde. Für die Bereinigung wurde im nächsten Bereinigungs-schritt diese Spalte herangezogen, wobei der Wert entweder „TRUE“ oder „FALSE“ ist. In diesem Schritt wurden alle Zeilen mit dem Wert „FALSE“ gefiltert und für die weiteren Analysen nicht berücksichtigt.

Insgesamt gab es 253 Zugriffe auf den Fragebogen. Davon wurden 35 Fragebögen nicht vollständig ausgefüllt oder waren eine Umfragevorschau zum Testen des Fragebogens und somit aus der Analyse ausgeschlossen, während 218 vollständig ausgefüllte Fragebögen in die Auswertung einbezogen wurden.

4.3.2 Stichprobeanalyse

Nach der Datenaufbereitung besteht die finale Stichprobe aus 218 Datensätzen, die den zuvor definierten Einschlusskriterien entsprechen. Zu Beginn des Fragebogens wurden demografische Merkmale der Teilnehmenden erfasst, um ein umfassendes Bild der

Zusammensetzung der Stichprobe zu erhalten. Im Anschluss daran werden diese Merkmale sowohl in absoluten Zahlen als auch in relativen Anteilen analysiert und tabellarisch dargestellt.

Die folgende Tabelle gibt einen Überblick über die absolute und relative Häufigkeit der Altersgruppen der Teilnehmer:innen innerhalb der Stichprobe:

Tabelle 3

Verteilung der Teilnehmerinnen auf Altersgruppen

Altersgruppe	Absolute Anzahl	Relative Anzahl
18-24	45	20.64
25-34	67	30.73
35-44	39	17.89
45-54	36	16.51
55-64	20	9.17
65 Jahre oder älter	10	4.59
Keine Angabe	1	0.46

Darüber hinaus wurde auch das Geschlecht der befragten Personen erhoben, um geschlechtsspezifische Unterschiede in der Wahrnehmung und im Verhalten analysieren zu können. Die folgende Tabelle stellt die Geschlechterhäufigkeit der Proband:innen dar:

Tabelle 4

Verteilung der Teilnehmerinnen auf Geschlechter

Geschlecht	Absolute Anzahl	Relative Anzahl
Männlich	68	31.19
Weiblich	147	67.43
Divers	0	0
Möchte ich nicht angeben	3	1.38

Zusätzlich wurde der höchste Bildungsabschluss der Teilnehmenden erfasst, um Rückschlüsse auf mögliche Zusammenhänge zwischen Bildungsniveau und der Bewertung von Online-Werbung ziehen zu können. Die folgende Tabelle zeigt die Verteilung der höchsten Bildungsabschlüsse:

Tabelle 5

Verteilung der höchsten Bildungsabschlüsse von Teilnehmer:innen

Höchster Bildungsabschluss	Absolute Anzahl	Relative Anzahl
Keinen Schulabschluss	38	17.43
Hauptschulabschluss	54	24.7799.99
Mittlere Reife (Realabschluss)	36	16.51
Fachabitur	9	4.13
Allgemeine Hochschulreife (Abitur)	1	0.46
Berufsausbildung (ohne Studium)	1	0.46
Bachelor-Abschluss	52	23.85
Master-Abschluss	5	2.29
Promotion (Dr./PhD)	1	0.46
Möchte ich nicht angeben	21	9.63

Ein weiterer Abschnitt des Fragebogens widmete sich dem Onlinekaufverhalten der Teilnehmenden. Hier wurde unter anderem erhoben, wie häufig die Befragten online einkaufen. Die anschließende Tabelle zeigt die absolute und relative Anzahl der Onlinekäufe der Proband:innen:

Tabelle 6

Die Anzahl der Häufigkeit der Onlinekäufe von Teilnehmer:innen

Häufigkeit der Onlinekäufe	Absolute Anzahl	Relative Anzahl
Häufig	79	36.24
Gelegentlich	82	37.61
Selten	8	3.67
Nie	49	22.48

Letztlich wurde das generelle Interesse an Online-Werbung abgefragt. Die Teilnehmenden konnten auf einer Skala von 1 bis 5 angeben, wie stark sie sich für Online-Werbung interessieren, wobei 1 „überhaupt nicht interessiert“ und 5 „sehr interessiert“ bedeutete.

Tabelle 7

Interesse an Online-Werbung

Interesse an Online-Werbung	Absolute Anzahl	Relative Anzahl
1	28	12.84
2	37	16.97
3	54	24.77
4	48	22.02
5	51	23.39

4.3.3 Vorbereitende Analyse

Für die anschließende Analyse mussten entsprechende Vorbereitungen getroffen werden.

Um die Reliabilität der Ergebnisse und insbesondere die Konsistenz der Bearbeitung von Skalen durch die Teilnehmer:innen zu überprüfen, wurde das Maß Cronbachs Alpha herangezogen (Schecker, 2014, S. 1). Cronbachs Alpha (α) dient der Einschätzung der internen Konsistenz einer Skala, das heißt, es gibt Auskunft darüber, wie stark die einzelnen Items einer Skala miteinander korrelieren und somit ein gemeinsames Konstrukt messen. Der Wert von α liegt zwischen 0 und 1; je höher der Wert, desto stärker ist die Korrelation zwischen den Items. Ein α -Wert von über 0,7 gilt dabei in der Regel als akzeptabel und weist auf eine zufriedenstellende interne Konsistenz hin. Voraussetzung für die Berechnung von Cronbachs Alpha ist, dass alle Skalenitems auf dasselbe latente Konstrukt abzielen. Zur genaueren Bewertung einzelner Items wurde eine Item-Drop-Analyse durchgeführt. Dabei wird Cronbachs Alpha jeweils erneut berechnet, nachdem ein Item aus der Skala entfernt wurde. So lässt sich erkennen, ob ein bestimmtes Item die interne Konsistenz der Skala verbessert oder verschlechtert. Items, deren Entfernung zu einem höheren Alpha führt, gelten als potenziell ungeeignet, da sie das Gesamtkonstrukt weniger gut abbilden. Die Methode hilft dabei, die Skala theoretisch und statistisch zu optimieren. (Taber, 2018, S. 1273ff). In dieser Untersuchung beziehen sich die meisten verwendeten Ordinalskalen auf Einschätzungen mit einer fünfstufigen Multi-Item-Likert-Skala. Diese reichen typischerweise von 1 („überhaupt nicht interessiert“) bis 5 („sehr interessiert“).

Die folgende Tabelle gibt einen Überblick über alle Fragen mit ordinalskalierten Antwortformaten sowie deren jeweilige Reliabilitätswerte, sofern mehrere Items zu einem gemeinsamen Konstrukt zusammengefasst wurden:

Tabelle 8

Überprüfung der Konsistenz von Itemgruppen mit Cronbachs α

Multi-Item-Likert-Skala	Itemanzahl	Cronbachs Alpha α
Wie besorgt sind Sie über den Schutz Ihrer persönlichen Daten im Internet?	5	0.78
Wie gut passt die gezeigte Werbung zu Ihren Interessen?	5	0.78
Wie ansprechend finden Sie diese Werbung?	5	0.79
Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?	5	0.77
Wie vertrauenswürdig finden Sie diese Werbung?	5	0.79
Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?	5	0.76
Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden?	5	0.75
Haben Sie das Gefühl, dass Ihre persönlichen Daten ohne Ihr Wissen für diese Werbung verwendet wurden?	5	0.77
Wie sehr sind Sie über Datenschutz besorgt?	5	0.78

Die Tabelle zeigt, dass alle α -Werte über 0.7 sind und keine der Fragen von der Skalenbildung ausgeschlossen werden muss.

Weiters gehört unter anderem die numerische Umkodierung jener Fragen, deren Antwortmöglichkeiten auf Ordinalskalen basierten. Der Großteil der Fragen im Fragebogen wies eine ähnliche Struktur auf, insbesondere im Hinblick auf die verwendeten Likert-Skalen. Diese bestanden meist aus fünf abgestuften Antwortoptionen, die in absteigender Reihenfolge angeordnet waren und beispielsweise Möglichkeiten von „überhaupt nicht interessiert“ bis hin zu „sehr interessiert“ haben.

Eine Ausnahme stellte die Frage zum Onlinekaufverhalten dar, bei der die Antwortmöglichkeiten „häufig“, „gelegentlich“, „selten“ und „nie“ vorgegeben waren. Auch diese wurde entsprechend ordinal skaliert und numerisch kodiert, um sie in die statistische Auswertung einbeziehen zu können. Dabei wird „nie“ auf 1, „selten“ auf 2, „gelegentlich“ auf 3 und „häufig“ auf 4 umkodiert.

Die folgenden Fragen mit den beschriebenen Likert-Skalen wurden nach dem gleichen Prinzip umkodiert, wobei den Antwortkategorien jeweils, wie bereits erwähnt, numerische Werte von 1 bis 5 zugewiesen wurden, wobei höhere Werte stets eine stärkere Zustimmung oder Ausprägung darstellten.

- Wie interessiert sind Sie an Online-Werbung? (1 = überhaupt nicht interessiert, 5 = sehr interessiert)
- Wie besorgt sind Sie über den Schutz Ihrer persönlichen Daten im Internet? (1 = überhaupt nicht besorgt, 5 = sehr besorgt)
- Wie gut passt die gezeigte Werbung zu Ihren Interessen? (1 = überhaupt nicht passend, 5 = sehr passend)
- Wie ansprechend finden Sie diese Werbung? (1 = überhaupt nicht ansprechend, 5 = sehr ansprechend)
- Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden? (1 = sehr unwahrscheinlich 5 = sehr wahrscheinlich)
- Wie vertrauenswürdig finden Sie diese Werbung? (1 = überhaupt nicht vertrauenswürdig, 5 = sehr vertrauenswürdig)
- Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat? (1 = überhaupt nicht besorgt, 5 = sehr besorgt)
- Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden? (1 = überhaupt nicht überwacht, 5 = sehr stark überwacht)
- Haben Sie das Gefühl, dass Ihre persönlichen Daten ohne Ihr Wissen für diese Werbung verwendet wurden? (1 = überhaupt nicht, 5 = ja, sehr stark)
- Wie sehr sind Sie über Datenschutz besorgt? (1 = überhaupt nicht besorgt, 5 = sehr besorgt)

Zu Beginn des Fragebogens wurde den Teilnehmenden zufällig entweder ein Hinweistext angezeigt, in dem auf die Verarbeitung persönlicher Daten hingewiesen wurde, oder kein entsprechender Hinweis gegeben. Zusätzlich wurden die Teilnehmenden entweder der Experimentalgruppe oder der Kontrollgruppe zugewiesen. Aus der Kombination dieser beiden Faktoren ergeben sich insgesamt vier mögliche Gruppenzuordnungen. Um diese Konstellationen im Datensatz klar zu unterscheiden und statistisch auswertbar zu machen, wurden sie entsprechend kodiert. Die folgende Tabelle gibt einen Überblick über die verwendete Gruppenzuordnung und deren jeweilige Kodierung:

Tabelle 9

Kodierungen der Gruppenzuordnungen von Proband:innen

Kodierung	Gruppenzuordnungsmöglichkeiten
A	Kein Hinweistext + Kontrollgruppe
B	Kein Hinweistext + Experimentalgruppe
C	Hinweistext + Kontrollgruppe
D	Hinweistext + Experimentalgruppe

Basierend auf die Umkodierungen der Fragen wurde noch eine Faktoranalyse durchgeführt, um sicherzustellen, dass die Fragen tatsächlich das messen, was sie messen sollen. Die explorative Faktorenanalyse ist ein Verfahren zur Identifikation zugrunde liegender latenter Strukturen in einer Vielzahl beobachteter Variablen. Dabei werden sogenannte Faktorladungen berechnet, die angeben, wie stark eine Variable mit einem Faktor zusammenhängt. Faktorladungen lassen sich interpretieren als Korrelationen zwischen einer manifesten Variable und dem Faktor und geben an, inwieweit die Ausprägung einer Variable durch diesen Faktor erklärt wird. Ladungen ab 0,3 als bedeutsam, während für die eindeutige Zuordnung zu einem Faktor häufig nur Items mit Ladungen über 0,5 verwendet werden sollten, sofern sie nicht gleichzeitig auf andere Faktoren > 0,3 laden (Wolff & Bacher, 2010, S. 15ff).

Zur weiteren Analyse wurden die Skalen „Werbeakzeptanz“ und „Datenschutzbedenken“ gebildet, indem thematisch zusammengehörige Fragen jeweils einer Skala zugeordnet wurden. Die Zuordnung basiert auf inhaltlicher Ähnlichkeit sowie den Ergebnissen der Faktorenanalyse. In der folgenden Tabelle ist dargestellt, welche konkreten Fragenitems den jeweiligen Skalen zugeordnet wurden:

Tabelle 10

Zuordnung der Einzelfragen zu den gebildeten Skalen „Werbeakzeptanz“ und „Datenschutzbedenken“

Werbeakzeptanz	Datenschutzbedenken
Wie gut passt die gezeigte Werbung zu Ihren Interessen?	Wie besorgt sind Sie über den Schutz Ihrer persönlichen Daten im Internet?
Wie ansprechend finden Sie diese Werbung?	Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden?
Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?	Haben Sie das Gefühl, dass Ihre persönlichen Daten ohne Ihr Wissen für diese Werbung verwendet wurden?
Wie vertrauenswürdig finden Sie diese Werbung?	Wie sehr sind Sie über Datenschutz besorgt?
Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?	

Die folgende Tabelle zeigt die höchsten Faktorladungen mit dem zugeordneten Faktor für folgende Fragen:

Tabelle 11

Höchste Faktorladungen mit zugeordnetem Faktor pro Frage

Frage	Zugeordneter Faktor	Faktorladung
Wie gut passt die gezeigte Werbung zu Ihren Interessen?	Werbewahrnehmung	-0.89
Wie ansprechend finden Sie diese Werbung?	Werbewahrnehmung	-0.95
Wie besorgt sind Sie über den Schutz Ihrer persönlichen Daten?	Datenschutzbedenken	-0.55
Wie interessiert sind Sie an Online-Werbung?	Nutzung/Interesse	-0.59
Wie häufig kaufen Sie online ein?	Nutzung/Interesse	-0.41

Die Ergebnisse der Faktorenanalyse zeigen, dass die eingesetzten Items weitgehend das messen, was sie messen sollen. So laden die beiden Fragen zur Bewertung der Werbung („Wie gut passt die gezeigte Werbung zu Ihren Interessen?“ und „Wie ansprechend finden Sie diese Werbung?“) mit hohen Ladungen von -0,89 bzw. -0,95 auf

denselben Faktor, was auf eine gemeinsame Dimension der Werbewahrnehmung hinweist. Die Frage zu Datenschutzbedenken („Wie besorgt sind Sie über den Schutz Ihrer persönlichen Daten?“) bildet mit einer Ladung von $-0,55$ einen eigenständigen Faktor ab, der als Privatsphäre-bezogene Einstellung interpretierbar ist. Ebenso laden die Fragen zur Mediennutzung („Wie interessiert sind Sie an Online-Werbung?“ und „Wie häufig kaufen Sie online ein?“) auf einen dritten Faktor und bilden damit eine eigene Dimension, die als Nutzungskontext oder Medienaffinität verstanden werden kann. Die klare Zuordnung der Items zu inhaltlich sinnvollen Faktoren spricht für die Konstruktvalidität der erhobenen Skalen.

4.3.4 Überprüfung der Voraussetzungen für die Hypothesenprüfung

Bevor Hypothesen überprüft werden können, müssen zunächst bestimmte Vorbedingungen für die Analyse der Hypothesen erfüllt sein. Diese Vorbedingungen stellen sicher, dass die angewendeten statistischen Verfahren gültige und aussagekräftige Ergebnisse liefern.

Für die Überprüfung der Hypothesen im nächsten Kapitel wird vor allem die Varianzanalyse (ANOVA) verwendet. Eine zentrale Voraussetzung für die Anwendung der ANOVA ist, dass die abhängigen Variablen normalverteilt sind (Bittner, 2022). Daher muss im Vorfeld überprüft werden, ob diese Bedingung erfüllt ist. Nur wenn die Normalverteilung der abhängigen Variablen gegeben ist, kann die ANOVA sinnvoll und zuverlässig angewendet werden.

Der Shapiro-Wilk-Test ist ein statistisches Verfahren zur Überprüfung, ob eine Stichprobe aus einer normalverteilten Grundgesamtheit stammt, und wird vor allem in der Vorbereitung parametrischer Analysen wie der ANOVA eingesetzt. Der Test liefert als Ergebnis den sogenannten W-Wert, der ein Maß für die Übereinstimmung der Verteilung der Daten mit einer theoretischen Normalverteilung darstellt. Je näher der W-Wert bei 1 liegt, desto eher kann von einer Normalverteilung ausgegangen werden (Shapiro & Wilk, 1965).

Die erste Hypothese dieser Untersuchung lautet: „KI-gestützte personalisierte Werbung erhöht die Kaufbereitschaft der Konsument:innen im Vergleich zu nicht personalisierter Werbung.“ Um diese Hypothese zu überprüfen, wurden die Teilnehmenden in zwei Gruppen eingeteilt, wobei die unabhängige Variable die Gruppenzugehörigkeit darstellt. Die abhängige Variable ist die Kaufbereitschaft der Konsument:innen, welche mittels mehrerer Fragen dargestellt wurde: „Wie gut passt die gezeigte Werbung zu Ihren Interessen?“, „Wie ansprechend finden Sie diese Werbung?“ sowie „Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?“. Zur Prüfung der

Normalverteilung der Messwerte wurde der Shapiro-Wilk-Test herangezogen, wobei der nachfolgend dargestellte W-Wert Aufschluss über die Verteilungseigenschaften der erhobenen Daten gibt. Die folgende Tabelle zeigt das Ergebnis des Shapiro-Wilk-Tests für jede Frage und jeweils für die Kontroll- und Experimentalgruppe:

Tabelle 12

Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H1

Frage	Kontrollgruppe	Experimentalgruppe
Wie gut passt die gezeigte Werbung zu Ihren Interessen?	0.79	0.84
Wie ansprechend finden Sie diese Werbung?	0.86	0.85
Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?	0.88	0.87

Die Werte des Tests lagen in der Experimentalgruppe zwischen 0.84 und 0.87, in der Kontrollgruppe zwischen 0.79 und 0.88. Diese Werte deuten auf eine annähernde Normalverteilung der Daten hin, insbesondere da alle Teststatistiken im oberen Bereich des möglichen Werteintervalls zwischen null und eins liegen. Auch wenn der Test keine exakten p-Werte liefert, lässt sich aus den Ergebnissen ableiten, dass keine gravierenden Abweichungen von der Normalverteilung vorliegen. Damit kann die Voraussetzung der Normalverteilung für die Überprüfung von H1 als weitgehend erfüllt angesehen werden.

Zur Überprüfung der Normalverteilung von H2 „Bei bestehender Privatsphäre wird KI-gestützte personalisierte Werbung seitens der Konsument:innen positiver bewertet.“ wird als unabhängige Variable die Frage herangezogen, inwieweit sich die Befragten um den Schutz ihrer persönlichen Daten im Internet sorgen. Diese Variable liegt in Form einer kategorialen Skala mit mehreren Antwortmöglichkeiten vor, sodass für jede einzelne Ausprägung separat analysiert wird, ob die zugrunde liegenden Daten normalverteilt sind. Als abhängige Variablen dienen mehrere Fragen zur Werbewirkung, konkret: „Wie ansprechend finden Sie diese Werbung?“ sowie „Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?“. Die folgende Tabelle zeigt das Ergebnis des Shapiro-Wilk-Tests für H2:

Tabelle 13

Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H2

Grad der Datenschutzbedenken	Wie ansprechend finden Sie diese Werbung?	Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?
1	0.82	0.72
2	0.8	0.89
3	0.87	0.86
4	0.88	0.89
5	0.82	0.86

Die Ergebnisse des Tests lagen je nach Ausprägung zwischen 0.72 und 0.89. Die Werte deuten insgesamt auf eine akzeptable Annäherung an die Normalverteilung hin, wobei der Wert von 0.72 bei sehr niedrigen Datenschutzbedenken auf eine mögliche Abweichung hindeutet. In den übrigen Gruppen bewegen sich die Teststatistiken im Bereich zwischen 0.86 und 0.89, was als Hinweis auf eine weitgehend normalverteilte Datenstruktur interpretiert werden kann.

Für die Überprüfung von H3 wird ebenfalls die Normalverteilung der Daten mithilfe von Shapiro-Wilk-Tests geprüft. Die unabhängige Variable bildet eine Frage, die das Ausmaß der Besorgnis der Teilnehmenden hinsichtlich des Datenschutzes misst. Die Proband:innen werden dabei in zwei Gruppen unterteilt. Proband:innen die einen Wert zwischen 1 und 3 eingegeben haben, werden mit einem niedrigen Maß eingestuft und gruppiert. Die restlichen Teilnehmer:innen sind in der Gruppe mit einem hohen Maß. Als abhängige Variablen werden drei Fragen herangezogen. Die erste erfasst, wie ansprechend die Werbeinhalte von den Teilnehmenden wahrgenommen wurden, während die zweite darauf abzielt, die Wahrscheinlichkeit zu bestimmen, mit der die Befragten das in der Werbung dargestellte Produkt erwerben würden. Die dritte Frage misst den Grad der Sorge darüber, wie gut die Werbung die Interessen der Proband:innen erkannt hat. Durch diese Vorgehensweise soll festgestellt werden, ob sich die Wahrnehmung und die Kaufabsicht in Abhängigkeit vom individuellen Datenschutzbedürfnis systematisch unterscheiden, wobei die Überprüfung der Normalverteilung eine Grundlage für die Wahl geeigneter statistischer Testverfahren darstellt. Die folgende Tabelle zeigt das Ergebnis des Shapiro-Wilk-Tests für H3:

Tabelle 14

Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H3

Gruppe	A	B	C
Hoch	0.86	0.9	0.9
Niedrig	0.82	0.85	0.9

Anmerkungen. A: Wie ansprechend finden Sie diese Werbung? Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden? C: Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?

Die Ergebnisse des Shapiro-Wilk-Tests für die Variable, die die Sorge darüber erfasst, wie personalisierte Werbung individuelle Interessen erkennt, zeigen für beide Gruppen identische Teststatistiken von 0.90. Unabhängig davon, ob die befragten Personen eine niedrige oder hohe empfundene Nutzung ihrer Daten angegeben haben, lassen diese Werte auf eine gute Annäherung an die Normalverteilung schließen. Da die Teststatistiken nahe am maximalen Wert von eins liegen, kann davon ausgegangen werden, dass die Verteilung der Antworten keine relevanten Abweichungen von der Normalverteilung aufweist. Somit ist die Voraussetzung für den Einsatz parametrischer Verfahren im Rahmen der weiteren Analyse als erfüllt anzusehen.

Zur Überprüfung der Normalverteilung im Zusammenhang mit H4 wurde die unabhängige Variable erhoben, die das Ausmaß der Besorgnis der Teilnehmenden hinsichtlich des Datenschutzes widerspiegelt. In diesem Zusammenhang wurden drei abhängige Variablen berücksichtigt, die verschiedene Aspekte der Reaktion auf personalisierte Werbung erfassen. Diese beinhalten die subjektive Einschätzung, inwiefern die gezeigte Werbung zu den persönlichen Interessen der Befragten passt, die empfundene Attraktivität beziehungsweise Ansprechbarkeit der Werbung sowie die wahrgenommene Wahrscheinlichkeit, das beworbene Produkt tatsächlich zu kaufen. Alle Variablen wurden entsprechend auf Normalverteilung überprüft, um die Voraussetzungen für weiterführende statistische Analysen zu gewährleisten. Die folgende Tabelle bereitet eine Übersicht über die Ergebnisse des Tests:

Tabelle 15

Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H4

Grad der Datenschutzsorge	A	B	C
1	0.77	0.71	0.76
2	0.76	0.83	0.86
3	0.86	0.85	0.89
4	0.85	0.88	0.89
5	0.79	0.86	0.86

Anmerkungen. A: Wie gut passt die gezeigte Werbung zu Ihren Interessen?, B: Wie ansprechend finden Sie diese Werbung?, C: Wie wahrscheinlich ist es; dass Sie dieses Produkt aus der Werbung kaufen würden?

Die Ergebnisse des Shapiro-Wilk-Tests zur Überprüfung der Normalverteilung für die Variable der Kaufwahrscheinlichkeit in Abhängigkeit vom Ausmaß der Datenschutzsorge zeigten Teststatistiken zwischen 0.76 und 0.89. Diese Werte bewegen sich insgesamt im oberen Bereich des Wertebereichs zwischen null und eins und deuten somit auf eine weitgehend normalverteilte Datenstruktur hin. Der niedrigste Wert von 0.76 in der Gruppe mit sehr geringer Datenschutzsorge weist zwar auf eine leichte Abweichung hin. Insgesamt kann die Voraussetzung der Normalverteilung als erfüllt betrachtet werden, sodass die Variable in weiterführenden parametrischen Analysen wie der Varianzanalyse berücksichtigt werden kann.

Die Überprüfung von Hypothese 5 erfolgt anhand des Merkmals „Interesse an Online-Werbung“ als unabhängige Variable. Dabei wird untersucht, ob sich Gruppen mit unterschiedlichem Interesse an Online-Werbung in der Bewertung der Effektivität KI-personalisierter Werbung unterscheiden. Zur Bildung der Gruppen werden Teilnehmende mit den Ausprägungen 1, 2 oder 3 dem niedrigen Interesse und Teilnehmende mit den Ausprägungen 4 oder 5 dem hohen Interesse zugeordnet. Die abhängige Variable, die Effektivität der Werbung, wird durch mehrere Items erfasst. Diese beinhalten die Einschätzung, wie gut die gezeigte Werbung zu den eigenen Interessen passt, wie ansprechend die Werbung wahrgenommen wird und in welchem Ausmaß das Gefühl besteht, durch die Werbung überwacht zu werden. Die folgende Tabelle zeigt die Ergebnisse des Shapiro-Wilk-Tests zur Überprüfung der Normalverteilung für diese Hypothese:

Tabelle 16

Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H5

Interesse an Online-Werbung	A	B	C
Gering	0.88	0.89	0.91
Hoch	0.73	0.77	0.91

Anmerkungen. A: Wie gut passt die gezeigte Werbung zu Ihren Interessen?, B: Wie ansprechend finden Sie diese Werbung?, C: Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden?

Die Ergebnisse des Shapiro-Wilk-Tests zur Überprüfung der Normalverteilung für die Variable des Überwachungsgefühls durch personalisierte Werbung zeigen in beiden Gruppen nahezu identische Teststatistiken von 0.91. Unabhängig davon, ob die befragten Personen ein hohes oder geringes Interesse an Online-Werbung aufweisen, deuten diese Werte auf eine sehr gute Annäherung an die Normalverteilung hin. Da der Wert nahe bei eins liegt, kann davon ausgegangen werden, dass keine relevanten Abweichungen vorliegen. Die Voraussetzung der Normalverteilung ist somit für beide Gruppen erfüllt und erlaubt den Einsatz weiterer parametrischer Verfahren zur Überprüfung der Hypothese.

5 Interpretation der Ergebnisse

Aufbauend auf den vorbereitenden Analysen werden in diesem Kapitel die aufgestellten Hypothesen überprüft. Dabei wird erklärt, wie die Hypothesen überprüft werden und die Ergebnisse der Hypothesenüberprüfung geschildert.

5.1 Hypothesenüberprüfung

Im Folgenden werden die fünf aufgestellten Hypothesen überprüft und anhand der vorbereitenden Analyse untersucht, ob die Hypothesen bestätigt werden können oder nicht. Für die Überprüfung der Hypothesen wurde die Varianzanalyse (ANOVA) angewendet. Die ANOVA ist ein statistisches Verfahren zur Prüfung, ob sich die Mittelwerte von drei oder mehr unabhängigen Gruppen signifikant unterscheiden. Sie kommt zum Einsatz, wenn eine kontinuierliche abhängige Variable und eine oder mehrere kategoriale unabhängige Variablen vorliegen. Dabei wird die Gesamtvarianz in einen erklärten Anteil zwischen den Gruppen und einen unerklärten Anteil innerhalb der Gruppen aufgeteilt. Das Verhältnis dieser beiden Varianzanteile ergibt den F-Wert, während der p-Wert angibt, wie wahrscheinlich es ist, dass ein gefundener Unterschied rein zufällig entstanden ist. Die Hypothese wird angenommen, wenn der p-Wert unter dem festgelegten Signifikanzniveau, wie z. B. $\alpha = 0,05$, liegt, andernfalls wird sie verworfen (Sawyer, 2009, S. 27E ff).

5.1.1 Überprüfung von H1

Zur Überprüfung der Hypothese H1 „KI-gestützte personalisierte Werbung erhöht die Kaufbereitschaft der Konsument:innen im Vergleich zu nicht personalisierter Werbung“ wird eine ANOVA durchgeführt.

Dabei werden die Werte aus den Fragen „Wie gut passt die gezeigte Werbung zu Ihren Interessen?“, „Wie ansprechend finden Sie diese Werbung?“ und „Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?“ herangezogen und zwischen Kontrollgruppe und Experimentalgruppe verglichen.

Zur Vorbereitung der ANOVA wurde zunächst ein explorativer Boxplot erstellt, um die Verteilung der Bewertungen in Abhängigkeit von der Gruppenzugehörigkeit visuell darzustellen. Die unabhängige Variable bildet dabei die Gruppenzuweisung der Teilnehmenden, während die abhängigen Variablen die Einschätzungen zur Passung der Werbung zu den eigenen Interessen, zur Ansprechbarkeit der Werbung sowie zur Kaufwahrscheinlichkeit des beworbenen Produkts umfassen. Die folgende Abbildung zeigt die Boxplots mit der unabhängigen Variable der Gruppenzuteilung der Proband:innen und der abhängigen Variable in Form von den unterschiedlichen Fragen:




Abbildung 14: Verteilung der Bewertungen zur Werbewirkung (Passung zu Interessen, Ansprechbarkeit und Kaufwahrscheinlichkeit) nach Gruppen.

Die Boxplots liefern erste Hinweise auf potenzielle Unterschiede in der Wahrnehmung der Werbung zwischen der Experimental- und der Kontrollgruppe. Hinsichtlich der wahrgenommenen Passung der Werbung zu den eigenen Interessen sowie der Ansprechbarkeit der Werbung zeigt sich, dass die Experimentalgruppe im Median höhere Bewertungen abgibt als die Kontrollgruppe. Auch bei der Kaufwahrscheinlichkeit ist eine tendenziell höhere zentrale Tendenz in der Experimentalgruppe erkennbar, wobei die Verteilung in beiden Gruppen relativ breit gestreut ist. Insgesamt deuten die Boxplots auf systematische Unterschiede in den Bewertungen der Werbewirkung in Abhängigkeit von der Gruppenzugehörigkeit hin, was eine weiterführende Prüfung mittels einer Varianzanalyse zur Überprüfung statistischer Signifikanzen nahelegt.

Die folgende Tabelle zeigt das Ergebnis der ANOVA für die Hypothese H1:

Tabelle 17

ANOVA für die Hypothesenüberprüfung von H1

Frage	F-Wert	p-Wert
Wie gut passt die gezeigte Werbung zu Ihren Interessen?	0.57	0.45
Wie ansprechend finden Sie diese Werbung?	0.17	0.68
Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?	1.17	0.28

Basierend auf den Ergebnissen der ANOVA konnte kein signifikanter Unterschied in der Kaufbereitschaft und Zufriedenheit zwischen den Gruppen mit personalisierter und nicht personalisierter Werbung festgestellt werden. Die p-Werte lagen bei allen geprüften Variablen über dem Signifikanzniveau, wodurch die Nullhypothese nicht verworfen werden kann. Die Hypothese, dass KI-gestützte personalisierte Werbung die Kaufbereitschaft erhöht, wird durch die vorliegenden Daten somit nicht bestätigt.

5.1.2 Überprüfung von H2

Zur Überprüfung der Hypothese H2, dass bei bestehender Privatsphäre KI-gestützte personalisierte Werbung von Konsumentinnen und Konsumenten positiver bewertet wird, wurde die ANOVA durchgeführt. Die Gruppierung erfolgte auf Basis der Einschätzung der Teilnehmer:innen, wie besorgt sie über den Schutz ihrer Privatsphäre im Internet sind. Diese Einschätzung wurde als unabhängige Variable herangezogen, da sie das subjektive Empfinden von Privatsphäre abbildet. Als abhängige Variablen dienten zum einen die Einschätzung, wie ansprechend die Teilnehmenden die angezeigte Werbung empfanden, und zum anderen die Angabe, wie wahrscheinlich sie es fänden, das beworbene Produkt zu kaufen.

Zur Vorbereitung der ANOVA wurde wieder ein Boxplot erstellt, um die Verteilung der Bewertungen in Abhängigkeit von der Gruppenzugehörigkeit visuell darzustellen. Dabei wird die Gruppenzuweisung der Teilnehmerinnen und Teilnehmer basierend auf dem Grad ihrer Besorgnis über den Schutz persönlicher Daten im Internet verwendet. Dadurch entstehen für fünf Ausprägungen des Merkmals fünf Gruppen. Die abhängigen Variablen umfassen die Einschätzung zur Ansprechbarkeit der gezeigten Werbung sowie die Wahrscheinlichkeit eines Produktkaufs auf Grundlage der Werbung. Die folgende Abbildung zeigt die Boxplots mit der unabhängigen Variable der Gruppenzuteilung und den abhängigen Variablen in Form der jeweiligen Werbewirkungsindikatoren.

Zur besseren Unterscheidung der Gruppen wurde eine Farbkodierung verwendet, wobei jede Ausprägung der Besorgnis mit einer spezifischen Farbe im Boxplot dargestellt ist. Durch die nebeneinander angeordneten Boxplots lassen sich Unterschiede zwischen den Gruppen auf einen Blick erfassen und geben erste Hinweise auf potenzielle Effekte, die in der ANOVA näher untersucht werden. Die folgende Abbildung zeigt die Boxplots:




Abbildung 15: Boxplots der Einschätzungen zur Ansprechbarkeit der Werbung und zur Kaufwahrscheinlichkeit des beworbenen Produkts in Abhängigkeit vom Besorgnisgrad über den Schutz persönlicher Daten im Internet.

Die Boxplots liefern erste Hinweise auf potenzielle Unterschiede in der Wahrnehmung der Werbung in Abhängigkeit vom Ausmaß der Besorgnis über den Schutz persönlicher Daten im Internet. Hinsichtlich der Ansprechbarkeit der Werbung zeigen sich Unterschiede in den Medianwerten zwischen den einzelnen Gruppen, wobei insbesondere Teilnehmer:innen mit mittlerer bis höherer Besorgnis tendenziell höhere Bewertungen abgeben. Auch bei der Kaufwahrscheinlichkeit lässt sich eine Variation der zentralen Tendenz über die Gruppen hinweg beobachten, wobei die Streuung innerhalb einzelner Gruppen unterschiedlich ausgeprägt ist. Die Darstellung legt nahe, dass mit zunehmender Besorgnis Veränderungen in der Werbewirkung auftreten könnten. Insgesamt deuten die Boxplots auf systematische Unterschiede zwischen den Besorgnisgruppen hin, was eine weiterführende Analyse mittels ANOVA zur Überprüfung statistischer Signifikanzen rechtfertigt.

Die folgende Tabelle zeigt das Ergebnis der ANOVA für die Hypothese H2:

Tabelle 18

ANOVA für die Hypothesenüberprüfung von H2

Frage	F-Wert	p-Wert
Wie ansprechend finden Sie diese Werbung?	0.93	0.45
Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?	1.49	0.21

Die Ergebnisse der Varianzanalyse zeigen keine signifikanten Unterschiede in der Bewertung der Werbung in Abhängigkeit vom empfundenen Schutz der Privatsphäre. Somit lässt sich kein statistischer Zusammenhang zwischen der Wahrnehmung von Privatsphäre und einer positiveren Bewertung personalisierter Werbung feststellen. Die Hypothese wird daher durch die vorliegenden Daten nicht gestützt.

5.1.3 Überprüfung von H3

Zur Überprüfung der Hypothese H3 wurde eine ANOVA durchgeführt, bei der das Gefühlsmaß anhand ohne Wissen der Teilnehmer:innen erhobener Daten verwendet wurde und als unabhängige Variable diente. Teilnehmer:innen wurden in zwei Gruppen anhand des Gefühlsmaßes gruppiert. Proband:innen, die überhaupt nicht bis neutral bewertet hatten, wurden in die Gruppe mit niedrigen Gefühlsmaß gruppiert. Die restlichen Teilnehmer:innen wurden dann in die Gruppe mit hohem Gefühlsmaß zugeordnet. Dabei wurde erfasst, wie stark sich die Proband:innen über ihre Datensicherheit im digitalen Raum sorgten. Als abhängige Variablen wurden verschiedene Aspekte der Bewertung personalisierter Werbung herangezogen. Diese umfassten die Einschätzung, inwiefern die angezeigte Werbung zu den eigenen Interessen passte, wie ansprechend die Werbung wahrgenommen wurde, wie wahrscheinlich es wäre, das beworbene Produkt zu kaufen, sowie, ob bei den Teilnehmenden Besorgnis darüber bestand, wie genau die Werbung ihre persönlichen Interessen erkannt hatte. Durch diese mehrdimensionale Erfassung sollte ein umfassendes Bild darüber gewonnen werden, inwieweit das individuelle Datenschutzempfinden mit der Bewertung personalisierter Werbeeinhalte zusammenhängt.

Zur Vorbereitung der ANOVA zur Überprüfung der Hypothese H3 wurde wieder ein Boxplot erstellt, um die Verteilung der Bewertungen in Abhängigkeit vom Ausmaß der Datenschutzbedenken visuell darzustellen. Die folgende Abbildung zeigt drei Abschnitte mit Boxplots für die zwei Gruppen und den abhängigen Variablen in Form der Werbewirkung, der Sorgen über die Erkennung der Interessen und der Kaufabsicht. Dabei hat das

Ausmaß der Datenschutzbedenken fünf Ausprägungen als Antwortmöglichkeiten, die jeweils fünf Gruppen ergeben. Die x-Achse stellt die zwei Gruppen, einerseits Proband:innen mit niedrigem Gefühlsmaß und andererseits die Gruppe mit hohem Gefühlsmaß, dar. Die y-Achse zeigt jeweils die abhängige Variable pro Abschnitt. Die folgende Abbildung zeigt die unterschiedlichen Boxplots je Frage an:




Abbildung 16: Boxplots zur Verteilung der Werbewahrnehmung in Abhängigkeit vom Gefühl ungewollter Datenverwendung.

Die Boxplots deuten auf mögliche Unterschiede in der Wahrnehmung personalisierter Werbung in Abhängigkeit vom empfundenen Grad ungewollter Datenverwendung hin. Teilnehmende, die angaben, eher nicht das Gefühl zu haben, dass ihre Daten ohne ihr Wissen verwendet wurden, bewerteten die Ansprechbarkeit der Werbung im Median tendenziell positiver als jene, die sich stärker überwacht fühlten. Auch bei der Kaufwahrscheinlichkeit zeigt sich in der Gruppe mit niedrigerer wahrgenommener Datenverwendung eine etwas höhere zentrale Tendenz. Hinsichtlich der Sorge über die Art und Weise, wie die Werbung die individuellen Interessen erkannt hat, geben Personen mit einem höheren Gefühl der Überwachung deutlich höhere Bewertungen ab. Die unterschiedlichen Verteilungen und Medianwerte zwischen den Gruppen lassen darauf

schließen, dass das subjektive Empfinden von Datenmissbrauch einen Einfluss auf die Bewertung personalisierter Werbung haben kann.

Die folgende Tabelle zeigt das Ergebnis der ANOVA für H3:

Tabelle 19

ANOVA für die Hypothesenüberprüfung von H3

Frage	F-Wert	p-Wert
Wie ansprechend finden Sie diese Werbung?	0.41	0.52
Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden?	0.76	0.38
Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?	49.68	0.0

Die Ergebnisse zeigen, dass zwischen den Gruppen mit niedrigem und hohem Überwachungsgefühl kein signifikanter Unterschied hinsichtlich der Werbeansprache und der Kaufbereitschaft besteht. Jedoch zeigt sich ein hochsignifikanter Unterschied in der Variable zum Messen der Sorge, ob die Werbung die Interessen erkannt hat. Konsument:innen mit einem stärkeren Überwachungsgefühl empfinden deutlich mehr Unbehagen in Bezug auf die datenbasierte Personalisierung. Damit lässt sich schlussfolgern, dass das Überwachungsgefühl vor allem auf die Wahrnehmung der Werbeintelligenz wirkt, jedoch nicht direkt auf die Attraktivität oder Kaufintention. Die Hypothese wird somit nur in Bezug auf die Sorgekomponente bestätigt.

5.1.4 Überprüfung von H4

H4 „Konsument:innen mit hohem Bewusstsein für Datenschutz reagieren weniger positiv auf KI-gestützte personalisierte Werbung im Vergleich zu Konsument:innen mit einem geringen Bewusstsein für Datenschutz. Dadurch weisen Konsument:innen mit einem hohen Bewusstsein eine geringere Kaufbereitschaft als auch eine geringere Zufriedenheit mit KI-gestützte personalisierte Werbung auf.“

Um die Hypothese H4 zu überprüfen, wird als Maß für das Bewusstsein für Datenschutz die Frage herangezogen, wie stark sich die Teilnehmenden um Datenschutz sorgen. In Bezug auf die Bewertung der Werbung sowie die Kaufbereitschaft werden drei weitere Items berücksichtigt, nämlich wie gut die gezeigte Werbung zu den eigenen Interessen passt, wie ansprechend sie empfunden wird und wie wahrscheinlich es ist, dass das dargestellte Produkt gekauft würde. Es stellt sich die Frage, ob das Ausmaß des

Datenschutzbewusstseins die Wahrnehmung personalisierter Werbung beeinflusst und ob dieser Effekt je nach Art der Werbung unterschiedlich ausfällt.

Zur Vorbereitung der ANOVA zur Überprüfung von H4 wurde ein Boxplot erstellt, um die Verteilung der Bewertungen in Abhängigkeit vom Grad der Besorgnis über Datenschutz visuell darzustellen und erste Tendenzen zu über die Verteilung zu analysieren. Die folgende Abbildung veranschaulicht die Verteilung der Bewertungen für jede abhängige Variable im Vergleich zwischen den unterschiedlichen Gruppen der Datenschutzbesorgnis. Die folgende Abbildung zeigt die Verteilung der Werbewahrnehmung:




Abbildung 17: Boxplots der Einschätzungen zur Passung der Werbung zu den eigenen Interessen, zur Ansprechbarkeit der Werbung sowie zur Kaufwahrscheinlichkeit des beworbenen Produkts in Abhängigkeit vom Besorgnisgrad über den Schutz persönlicher Daten im Internet.

Die Boxplots liefern erste Hinweise auf potenzielle Unterschiede in der Wahrnehmung der Werbung in Abhängigkeit vom Ausmaß der Datenschutzbesorgnis. In Bezug auf die wahrgenommene Passung der Werbung zu den eigenen Interessen sowie die Ansprechbarkeit der Werbung zeigen sich zwischen den Gruppen unterschiedliche mediale Bewertungstendenzen, wobei insbesondere Teilnehmer:innen mit geringer bis mittlerer

Datenschutzbesorgnis tendenziell höhere Bewertungen abgeben. Auch bei der Kaufwahrscheinlichkeit lassen sich Unterschiede zwischen den Gruppen erkennen, obwohl die Verteilungen teilweise breiter gestreut sind. Insgesamt deuten die dargestellten Verteilungen auf potenzielle Zusammenhänge zwischen dem Besorgnisgrad über Datenschutz und der Bewertung der Werbung hin.

Da die Hypothese eine mögliche Wechselwirkung zwischen zwei unabhängigen Einflussfaktoren annimmt, nämlich dem Datenschutzbewusstsein, das entweder hoch oder niedrig ist, und der Art der Werbung, die in dieser Arbeit personalisiert oder nicht personalisiert ist, ist die Anwendung einer zweifaktoriellen Varianzanalyse erforderlich, um potenzielle Unterschiede in der Werbewirkung differenziert erfassen zu können. Die folgende Tabelle beschreibt das Ergebnis der ANOVA, wobei die Spalte „Faktor“ angibt, welche unabhängigen Variablen oder Kombinationen davon analysiert wurden, um deren Einfluss auf die Mittelwertunterschiede in den Zielgrößen zu bestimmen. Die folgende Tabelle zeigt das Ergebnis der zweifaktoriellen Varianzanalyse:

Tabelle 20

ANOVA für die Hypothesenüberprüfung von H4.

Frage	Faktor	F-Wert	p-Wert
Q21	Datenschutzbewusstsein	5.16	0.0241
Q21	C(Gruppe	0.695	0.4054
Q21	Datenschutzbewusstsein : Gruppe	0.637	0.4258
Q22	Datenschutzbewusstsein	6.744	0.0101
Q22	Gruppe	0.108	0.7433
Q22	Datenschutzbewusstsein : Gruppe	0.77	0.3812
Q27	Datenschutzbewusstsein	8.095	0.0049
Q27	Gruppe	1.423	0.2343
Q27	Datenschutzbewusstsein : Gruppe	1.07	0.3021

Q21 (Wie gut passt die gezeigte Werbung zu Ihren Interessen?), Q22 (Wie gut passt die gezeigte Werbung zu Ihren Interessen?) und Q27 (Wie wahrscheinlich ist es; dass Sie dieses Produkt aus der Werbung kaufen würden?)

Die Ergebnisse zeigen, dass das Datenschutzbewusstsein einen signifikanten Haupteffekt auf alle drei abhängigen Variablen hat. Konsument:innen mit höherem Datenschutzbewusstsein bewerteten die Werbung insgesamt als weniger passend, weniger ansprechend und zeigten eine geringere Kaufbereitschaft. Die Interaktionseffekte zwischen Datenschutzbewusstsein und Werbegruppe waren jedoch in keiner der Variablen

signifikant, was darauf hinweist, dass der Einfluss des Datenschutzbewusstseins unabhängig von der Art der Werbung auftritt. Die Hypothese wird somit nur teilweise bestätigt. Zwar reagieren datenschutzsensible Konsument:innen insgesamt negativer auf Werbung, jedoch nicht spezifisch stärker negativ auf personalisierte KI-Werbung.

5.1.5 Überprüfung von H5

H5 „Die Effektivität von KI-gestützter personalisierter Werbung ist stärker ausgeprägt bei Konsument:innen, die bereits vorher positive Erfahrungen mit ähnlichen Werbemaßnahmen gemacht haben, im Vergleich zu Konsument:innen ohne solche Vorerfahrungen.“

Für die Überprüfung der Hypothese H5 wurde auch eine ANOVA durchgeführt, bei der die Effektivität als abhängige Variable untersucht wurde. Diese wurde erfasst durch die Einschätzung der Proband:innen hinsichtlich der Aussagen, wie gut die gezeigte Werbung zu ihren Interessen passe, wie ansprechend sie die Werbung fanden und inwiefern sie das Gefühl hatten, durch die Werbung verstanden worden zu sein. Diese Items könnten unter Umständen auch zu einem Index zusammengeführt werden, um ein umfassenderes Maß der wahrgenommenen Effektivität zu ermöglichen. Die unabhängige Variable spiegelte das generelle Interesse der Teilnehmer:innen an Online-Werbung wider, welches anhand einer entsprechenden Frage erfasst wurde. Dabei wurden zwei Gruppen gebildet. Personen mit einem geringeren Interesse, das durch Werte zwischen eins und drei dargestellt wurde, wurden gruppiert, sowie Personen mit einem höheren Interesse, welches durch Werte von vier oder fünf zum Ausdruck kam, wurden in eine andere Gruppe kategorisiert.

Zur Vorbereitung der ANOVA wurde ein Boxplot erstellt, um die Verteilung der Bewertungen in Abhängigkeit von der Gruppenzugehörigkeit visuell zu veranschaulichen. Die folgende Abbildung zeigt die Boxplots, in denen die Gruppenzuteilung als unabhängige Variable den unterschiedlichen Bewertungen gegenübergestellt wird. Dabei wird pro abhängige Frage für jeweils den zwei Gruppen ein Boxplot erstellt. Die folgende Abbildung zeigt die Boxplots:




Abbildung 18: Boxplots zur Verteilung der Bewertungen dreier Werbewahrnehmungsaspekte in Abhängigkeit vom Interesse an Online-Werbung.

Die dargestellten Boxplots liefern erste Anhaltspunkte für potenzielle Unterschiede in der Bewertung der Werbung abhängig vom individuellen Interesse an Online-Werbung. Bei der Einschätzung der Passung der Werbung zu den eigenen Interessen sowie der empfundenen Ansprechbarkeit zeigen sich höhere Medianwerte in der Gruppe mit hohem Interesse, was auf eine positivere Wahrnehmung dieser Werbeaspekte hindeutet. Gleichzeitig ist bei der Einschätzung des Überwachungsgefühls erkennbar, dass Personen mit geringerem Interesse tendenziell höhere Werte angeben, was auf eine kritischere Wahrnehmung der Werbemaßnahmen schließen lässt. Die Verteilungen innerhalb der Gruppen verdeutlichen zudem Unterschiede in der Streuung und Ausprägung extremer Werte. Insgesamt lassen die Boxplots auf potenziell signifikante Unterschiede zwischen den Gruppen schließen, die im Rahmen einer nachfolgenden ANOVA detaillierter untersucht werden sollten.

Folgende Tabelle spiegelt das Ergebnis der ANOVA für H5 wider:

Tabelle 21

ANOVA für die Hypothesenüberprüfung von H5

Frage	F-Wert	p-Wert
Wie gut passt die gezeigte Werbung zu Ihren Interessen?	23.183	0.45
Wie ansprechend finden Sie diese Werbung?	26.34	
Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden?	0.0	0.21

Die Ergebnisse der Varianzanalyse zeigen signifikante Unterschiede in der Bewertung der Werbung zwischen Konsument:innen mit hohem und niedrigem Interesse an Online-Werbung. So unterscheiden sich insbesondere die wahrgenommene Passung der Werbung zu den eigenen Interessen sowie deren Ansprechbarkeit signifikant zwischen den Gruppen, wobei Personen mit höherem Interesse eine deutlich positivere Bewertung abgaben. Für das Gefühl, durch die Werbung verstanden worden zu sein, zeigte sich hingegen kein signifikanter Unterschied. Insgesamt stützen die Ergebnisse die Hypothese, dass die Effektivität von KI-gestützter personalisierter Werbung stärker ausgeprägt ist bei Konsument:innen, die bereits ein höheres Interesse an und potenziell Vorerfahrungen mit ähnlichen Werbemaßnahmen aufweisen.

Zur weiteren Untersuchung des Einflusses personalisierter Werbung auf das Kaufverhalten wurde eine Regressionsanalyse durchgeführt. Ziel dieser Analyse ist es, die Zusammenhänge zwischen verschiedenen wahrgenommenen Merkmalen der Werbung und der daraus resultierenden Kaufwahrscheinlichkeit zu prüfen. Im Fokus steht dabei die Frage, inwiefern spezifische Aspekte wie Relevanz, Attraktivität oder Vertrauen in die Werbung das Konsumverhalten beeinflussen.

Die Regressionsanalyse erlaubt es, den Beitrag einzelner Faktoren zu quantifizieren und damit ein differenziertes Verständnis der Wirkung personalisierter Werbeinhalte zu gewinnen. Sie ist ein statistisches Verfahren zur Untersuchung von Zusammenhängen zwischen einer abhängigen Variable und einer oder mehreren unabhängigen Variablen. Dadurch lässt sich nicht nur feststellen, ob ein Zusammenhang besteht, sondern auch in welchem Ausmaß einzelne Einflussgrößen auf ein bestimmtes Ergebnis wirken. In der Werbewirkungsforschung kann so beispielsweise analysiert werden, welchen Einfluss verschiedene Elemente wie Inhalt, Format oder Zielgruppenansprache auf die Reaktion der Nutzer haben. Die Regressionsanalyse eignet sich besonders gut, um Hypothesen

über Wirkungszusammenhänge empirisch zu überprüfen und Vorhersagen zu treffen (Backhaus, Erichson, Plinke & Weiber, 2018, S. 30ff).

Als Prädiktoren wurden zentrale Dimensionen der Werbewahrnehmung berücksichtigt. Hierzu zählt unter anderem die wahrgenommene Relevanz der Anzeige für die eigenen Interessen sowie deren gestalterische Attraktivität. Darüber hinaus wurden auch das Vertrauen in die Werbung, das subjektive Gefühl der Personalisierung sowie Datenschutzbedenken und Sorgen über die Datenverwendung einbezogen. Diese Variablen wurden gewählt, da sie in der Forschung zu digitaler Werbung und Personalisierung regelmäßig als zentrale Einflussgrößen auf die Reaktion der Konsument:innen identifiziert werden (Aguirre, Mahr, Grewal, Ruyter & Wetzels, 2015, S. 34ff; Dolin et al., 2018, S. 1ff). Die Analyse zielt darauf ab, die relative Bedeutung dieser Faktoren im Kontext personalisierter Online-Werbung zu bestimmen. Für diese Analyse wurde ein Konfidenzintervall von 2.5% und 97.5% gewählt (Field, 2018, S. 62).

Im Rahmen dieser Arbeit wurde die Regressionsanalyse auf Basis einzelner Items durchgeführt, ohne die verwendeten Variablen zu Skalen zusammenzufassen. Die jeweiligen Frageformulierungen aus dem Fragebogen wurden direkt in das Modell übernommen, um den Einfluss spezifischer Wahrnehmungsdimensionen individuell und differenziert untersuchen zu können. Dieser Ansatz ermöglicht es, die Wirkung einzelner Aspekte wie Relevanz, Attraktivität oder Vertrauen präzise zu erfassen, anstatt sie in zusammengefassten Variablen zu verallgemeinern. Die Entscheidung, auf eine Skalenbildung zu verzichten, basiert auf der Annahme, dass die inhaltlich klar umrissenen Konstrukte durch einzelne Items adäquat abgebildet werden können, wie es auch in der Forschungsliteratur zur Validität von Items und Regressionsmodellierung anerkannt ist (Diamantopoulos, Sarstedt, Fuchs, Wilczynski & Kaiser, 2012, S. 447ff).

Die folgende Tabelle zeigt das Ergebnis der Analyse:

Tabelle 22

Einfluss ausgewählter Wahrnehmungsdimensionen auf die Kaufwahrscheinlichkeit

Frage	Koeffizient	p-Wert	Konfidenzinter- vall (2.5%)	Konfidenzinter- vall (97.5%)
A	0.22	0.03	0.02	0.42
B	0.39	0.0	0.19	0.6
C	0.1	0.21	-0.06	0.26
D	-0.02	0.76	-0.17	0.12
E	0.38	0.0	0.24	0.52
F	-0.14	0.06	-0.27	0.0

Anmerkungen: A: Wie gut passt die gezeigte Werbung zu Ihren Interessen?, B: Wie ansprechend finden Sie diese Werbung?, C: Inwiefern hatten Sie das Gefühl; durch die gezeigte Werbung überwacht zu werden?, D: Haben Sie das Gefühl, dass Ihre persönlichen Daten ohne Ihr Wissen für diese Werbung verwendet wurden?, E: Wie vertrauenswürdig finden Sie diese Werbung?, F: Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?

Die Ergebnisse der Regressionsanalyse zeigen, dass insbesondere die wahrgenommene Attraktivität der Werbung sowie das Vertrauen in deren Inhalte positiv mit der Kaufwahrscheinlichkeit zusammenhängen. Auch die Relevanz der Werbung für die eigenen Interessen weist einen signifikanten positiven Einfluss auf, wenn auch in geringerem Ausmaß. Diese Ergebnisse deuten darauf hin, dass gestalterische und inhaltliche Merkmale der Werbung, die als ansprechend und glaubwürdig wahrgenommen werden, maßgeblich zur Kaufabsicht beitragen können.

Demgegenüber zeigen sich weder für das subjektive Gefühl, durch die Werbung überwacht worden zu sein, noch für die Sorge um die unbewusste Nutzung persönlicher Daten signifikante Zusammenhänge mit dem Kaufverhalten. Auch das Gefühl der Überwachung durch die Werbung bleibt ohne statistisch belastbaren Einfluss. Insgesamt verdeutlichen die Ergebnisse, dass emotionale und kognitive Dimensionen der Werbewahrnehmung, wie Vertrauen und Attraktivität, für die Wirksamkeit personalisierter Werbung entscheidender sind als Datenschutzbedenken oder wahrgenommene Kontrollverluste. Die Analyse erfolgte auf Basis einzelner Items, wobei keine Skalen gebildet wurden. Die verwendeten Antwortformate folgten einer fünfstufigen Likert-Skala und wurden direkt als metrisch interpretierte Variablen in das Regressionsmodell aufgenommen.

Zur Analyse der Zusammenhänge zwischen der Wahrnehmung personalisierter Werbung wurde eine Korrelationsanalyse durchgeführt. Ziel dieser Analyse ist es, systematische Beziehungen zwischen verschiedenen Dimensionen der Werbewahrnehmung zu identifizieren. Im Mittelpunkt steht die Frage, inwiefern zentrale Merkmale wie Relevanz,

Attraktivität oder Vertrauen miteinander in Verbindung stehen und gemeinsam die subjektive Wahrnehmung von Personalisierung prägen. Die Korrelationsanalyse ermöglicht es, wechselseitige Zusammenhänge zwischen den untersuchten Variablen aufzuzeigen und erste Hinweise auf mögliche Wirkungsmechanismen zu liefern.

Berücksichtigt wurden zentrale Aspekte der Wahrnehmung personalisierter Werbung. Dazu zählen unter anderem die Passung der Anzeige zu den eigenen Interessen sowie die visuelle und inhaltliche Attraktivität der Werbung. Ebenfalls einbezogen wurden das Vertrauen in die gezeigte Anzeige sowie das Gefühl, durch personalisierte Inhalte überwacht zu werden. Ergänzend wurden Datenschutzbedenken und Sorgen über die unbemerkte Verwendung persönlicher Daten in die Analyse aufgenommen. Diese Merkmale gelten in der bestehenden Forschungsliteratur als zentrale Einflussfaktoren für die Akzeptanz und Wirkung digitaler Werbeformate (Davis, 1989, S. 319; Petty & Cacioppo, 1986, S. 5). Die Korrelationsanalyse dient somit als Grundlage für ein vertieftes Verständnis der Zusammenhänge zwischen personalisierter Ansprache und individueller Wahrnehmung im digitalen Werbekontext.

Die folgende Tabelle zeigt die Korrelationsmatrix mit den Zusammenhängen zwischen verschiedenen Aspekten der Wahrnehmung personalisierter Werbung. Diese Matrix ermöglicht erste Einblicke in deren wechselseitige Beziehungen:

Tabelle 23

Einfluss ausgewählter Wahrnehmungsdimensionen auf die Kaufwahrscheinlichkeit

	A	B	C	D	E	F	G
A	1.0	0.86	0.67	0.56	0.18	0.2	0.06
B	0.86	1.0	0.72	0.64	0.13	0.11	-0.01
C	0.67	0.72	1.0	0.65	0.04	0.1	-0.03
D	0.56	0.64	0.65	1.0	0.07	0.05	-0.07
E	0.18	0.13	0.04	0.07	1.0	0.6	0.5
F	0.2	0.11	0.1	0.05	0.6	1.0	0.68
G	0.06	-0.01	-0.03	-0.07	0.5	0.68	1.0

A: Wie gut passt die gezeigte Werbung zu Ihren Interessen?, B: Wie ansprechend finden Sie diese Werbung?, C: Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden?, D: Haben Sie das Gefühl, dass Ihre persönlichen Daten ohne Ihr Wissen für diese Werbung verwendet wurden?, E: Wie vertrauenswürdig finden Sie diese Werbung?, F: Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?

Die Ergebnisse der Korrelationsanalyse zeigen, dass insbesondere die wahrgenommene Passung der Werbung zu den eigenen Interessen stark mit der Attraktivität der Anzeige zusammenhängt. Auch die Kaufwahrscheinlichkeit weist eine deutliche positive Korrelation mit diesen beiden Dimensionen auf. Vertrauen in die Werbung steht in einem moderaten Zusammenhang mit Relevanz, Attraktivität und Kaufabsicht, was darauf hinweist, dass glaubwürdige Inhalte eine zentrale Rolle für die positive Wahrnehmung personalisierter Werbung spielen können.

Im Gegensatz dazu zeigen sich für Datenschutzbedenken wie das Gefühl der Überwachung oder die Sorge über die Nutzung persönlicher Daten nur schwache bis negative Korrelationen mit positiven Bewertungsdimensionen. Diese Aspekte scheinen in ihrer Wirkung eher unabhängig von der unmittelbaren Kaufabsicht oder der wahrgenommenen Attraktivität zu sein. Insgesamt unterstreichen die Ergebnisse, dass kognitive und emotionale Einschätzungen wie Relevanz und Vertrauen stärker miteinander verknüpft sind als wahrgenommene Risiken in Bezug auf Datenschutz.

6 Zusammenfassung und Handlungsempfehlungen

In diesem Kapitel werden die zentralen Ergebnisse der empirischen Untersuchung zusammenfassend dargestellt, bestehende Limitationen der Studie kritisch reflektiert und Implikationen für weiterführende Forschung aufgezeigt.

6.1 Zusammenfassung der Ergebnisse

Ziel dieser Forschungsarbeit ist es, die Auswirkungen der Nutzung von KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Kaufverhalten von Konsument:innen zu untersuchen.

Für Marketingfachleute und Unternehmen ist es essenziell, zu verstehen, wie KI-basierte Personalisierung effektiv eingesetzt werden kann, um den Return on Investment (ROI) zu maximieren. Eine gezielte und präzise Personalisierung trägt nicht nur zur Steigerung der Effizienz von Marketingkampagnen bei, sondern fördert auch die Kundenbindung, indem sie individuell zugeschnittene Erlebnisse schafft (Coelho et al., 2006, S. 321).

Auch für Konsument:innen ist das Thema von großer Relevanz, da es zur Förderung von Transparenz und Bewusstsein im Umgang mit personalisierten Technologien beiträgt. In einer zunehmend digitalisierten Welt wird es immer bedeutender, die Auswirkungen solcher Technologien auf das individuelle Konsumverhalten zu verstehen.

Um diese Problematik zu untersuchen, wurde die folgende Forschungsfrage aufgestellt:

„Welche Auswirkungen hat die Nutzung von KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Kaufverhalten der Konsument:innen?“

Um diese Forschungsfrage zu beleuchten, wurden 5 Hypothesen aufgestellt, die im Rahmen vom vorigen Kapitel analysiert wurden. Mit Hilfe von einem Fragebogen wurden quantitative Daten gesammelt und gefiltert. Insgesamt wurden 216 Fragebogen vervollständigt.

Im Rahmen der vorbereitenden Analysen wurde zunächst die Reliabilität der erhobenen Skalen überprüft sowie die Konsistenz der Antworten der Teilnehmer:innen untersucht. Hierfür wurde Cronbachs Alpha berechnet, um die interne Konsistenz der Skalen zu bewerten. Da die meisten Fragen eine ähnliche Struktur und vergleichbare Items aufwiesen, eignete sich dieses Verfahren besonders gut. Die Ergebnisse zeigten, dass die Reliabilität der verwendeten Skalen zufriedenstellend war und keine Items ausgeschlossen werden mussten. Somit konnten alle Fragen in die weiteren Hypothesenüberprüfungen einbezogen werden. Diese Fragebögen wurden nach der vorbereitenden Analyse durch Kodierungen vorbereitet, um die Überprüfung zu erleichtern.

Im Vorfeld der Hypothesenüberprüfungen wurden die Voraussetzungen für die Anwendung der geplanten statistischen Tests geprüft. Da die Hypothesenprüfungen auf Verfahren beruhen, die eine annähernde Normalverteilung der erhobenen Daten erfordern, wurde zur Überprüfung der Verteilung der Shapiro-Wilk-Test eingesetzt. Für jede in den Hypothesen betrachtete Variable wurde separat geprüft, ob die Normalverteilungsannahme erfüllt ist. Die Ergebnisse des Shapiro-Wilk-Tests zeigten, dass die Verteilungen der erhobenen Daten die Voraussetzung der Normalverteilung weitgehend erfüllen, so dass die Hypothesenüberprüfungen auf dieser Basis durchgeführt werden konnten.

Im Rahmen der Hypothesenüberprüfungen wurde zunächst Hypothese H1 „KI-gestützte personalisierte Werbung erhöht die Kaufbereitschaft der Konsument:innen im Vergleich zu nicht personalisierter Werbung“ geprüft. Zuerst wurden Boxplots erstellt, um die Verteilung zu visualisieren. Die Ergebnisse der durchgeführten ANOVA zeigten keine signifikanten Unterschiede zwischen der Experimental- und der Kontrollgruppe hinsichtlich wahrgenommener Werberelevanz, Attraktivität oder Kaufwahrscheinlichkeit. Die Hypothese konnte somit nicht bestätigt werden.

Auch Hypothese H2 „Bei bestehender Privatsphäre wird KI-gestützte personalisierte Werbung seitens der Konsument:innen positiver bewertet“ wurden Boxplots erstellt und es fand keine empirische Unterstützung der Hypothese. Die ANOVA ergab keinen signifikanten Einfluss der wahrgenommenen Privatsphäre auf die Bewertung der Werbung oder die Kaufabsicht.

Die Überprüfung von Hypothese H3 „Das Gefühl der Überwachung durch personalisierte Werbung kann die Bewertung der Konsument:innen negativ beeinflussen, unabhängig von der Werberelevanz“ zeigte ebenfalls keine signifikanten Unterschiede in der Bewertung der Werbung in Abhängigkeit vom empfundenen Überwachungsgefühl. Es wurde hier auch Boxplots erstellt, die visuell schon dieses Ergebnis unterstützen. Auch diese Hypothese wurde durch die empirischen Daten nicht gestützt.

Im Gegensatz dazu konnte Hypothese H4 „Konsument:innen mit hohem Bewusstsein für Datenschutz reagieren weniger positiv auf KI-gestützte personalisierte Werbung im Vergleich zu Konsument:innen mit einem geringen Bewusstsein für Datenschutz. Dadurch weisen Konsument:innen mit einem hohen Bewusstsein eine geringere Kaufbereitschaft als auch eine geringere Zufriedenheit mit KI-gestützte personalisierte Werbung auf.“ teilweise bestätigt werden. Auch bei dieser Hypothesenüberprüfung wurden zuerst Boxplots erstellt. Die zweifaktorielle ANOVA ergab signifikante Haupteffekte des Datenschutzbewusstseins auf die Wahrnehmung der Werbung sowie die Kaufabsicht. Jedoch traten keine signifikanten Interaktionseffekte mit der Art der Werbung auf.

Datenschutz sensible Personen bewerteten Werbung generell negativer, unabhängig davon, ob diese personalisiert war oder nicht.

Hypothese H5 „Die Effektivität von KI-gestützter personalisierter Werbung ist stärker ausgeprägt bei Konsument:innen, die bereits vorher positive Erfahrungen mit ähnlichen Werbemaßnahmen gemacht haben, im Vergleich zu Konsument:innen ohne solche Vorerfahrungen.“ hingegen konnte in weiten Teilen bestätigt werden. Auch für diese Hypothese wurden Boxplots erstellt, um die Verteilung zu visualisieren. Personen mit einem höheren allgemeinen Interesse an Online-Werbung bewerteten die Werbung signifikant positiver, insbesondere in Bezug auf Relevanz und Ansprechbarkeit. Dies deutet darauf hin, dass frühere positive Erfahrungen oder eine grundsätzlich aufgeschlosseneren Haltung gegenüber Online-Werbung die Wirksamkeit personalisierter Inhalte verstärken können.

Die folgende Tabelle fasst noch einmal die Hypothesen zusammen.

Tabelle 24

Zusammenfassung der Hypothesenüberprüfungen

Hypothese	Ergebnis
H1: „KI-gestützte personalisierte Werbung erhöht die Kaufbereitschaft der Konsument:innen im Vergleich zu nicht personalisierter Werbung.“	Nicht bestätigt: Es zeigte sich kein signifikanter Unterschied in der Kaufabsicht zwischen den Gruppen.
H2: „Bei bestehender Privatsphäre wird KI-gestützte personalisierte Werbung seitens der Konsument:innen positiver bewertet.“	Nicht bestätigt: Kein signifikanter Zusammenhang zwischen Privatsphäre-Empfinden und Werbewirkung.
H3: „Das Gefühl der Überwachung durch personalisierte Werbung kann die Bewertung der Konsument:innen negativ beeinflussen, unabhängig von der Werberelevanz.“	Nicht bestätigt: Keine signifikanten Effekte auf Werbewahrnehmung oder Kaufabsicht festgestellt.
H4: „Konsument:innen mit hohem Bewusstsein für Datenschutz reagieren weniger positiv auf KI-gestützte personalisierte Werbung im Vergleich zu Konsument:innen mit einem geringen Bewusstsein für Datenschutz. Dadurch weisen Konsument:innen mit einem hohen Bewusstsein eine geringere Kaufbereitschaft als auch eine geringere Zufriedenheit mit KI-gestützte personalisierte Werbung auf.“	Teilweise bestätigt: Datenschutzbewusstsein beeinflusst Bewertung und Kaufabsicht negativ, unabhängig von der Personalisierung.
H5: „Die Effektivität von KI-gestützter personalisierter Werbung ist stärker ausgeprägt bei Konsument:innen, die bereits vorher positive Erfahrungen mit ähnlichen Werbemaßnahmen gemacht haben, im Vergleich zu Konsument:innen ohne solche Vorerfahrungen.“	Bestätigt: Personen mit höherem Interesse bewerteten die Werbung signifikant positiver.

Ergänzend zu den Hypothesentests verdeutlichte eine Regressionsanalyse den Einfluss einzelner Wahrnehmungsdimensionen auf die Kaufwahrscheinlichkeit. Es zeigte sich, dass insbesondere die wahrgenommene Attraktivität der Werbung sowie das Vertrauen in ihre Inhalte signifikant positiv mit der Kaufabsicht korrelierten. Auch die Relevanz der Anzeige trug in moderatem Maße zur Kaufwahrscheinlichkeit bei. Im Gegensatz dazu zeigten Datenschutzbedenken, das Gefühl der Überwachung oder Sorgen über unbewusste Datennutzung keinen signifikanten Einfluss auf das Kaufverhalten. Diese Ergebnisse lassen den Schluss zu, dass emotionale und gestalterische Faktoren der Werbung eine stärkere Wirkung auf Konsumententscheidungen ausüben als datenschutzbezogene Bedenken.

6.2 Diskussion der Ergebnisse

Ziel dieser Arbeit war es, zu untersuchen, welche Auswirkungen die Nutzung von KI-gestützter Personalisierung in Online-Werbeanzeigen auf das Kaufverhalten der Konsumentinnen und Konsumenten hat. Die Ergebnisse liefern eine differenzierte Antwort auf diese Fragestellung und machen deutlich, dass die Wirkung personalisierter Werbung nicht pauschal positiv oder negativ ausfällt, sondern stark von individuellen Einstellungen und situativen Kontexten beeinflusst wird.

Die zentrale Variable dieser Untersuchung, die Kaufabsicht, wurde durch personalisierte Werbung zwar tendenziell positiv beeinflusst, jedoch nicht signifikant gesteigert. Die durchschnittliche Kaufabsicht lag in der personalisierten Bedingung bei 4.01 und in der nicht personalisierten bei 3.84. Trotz des erkennbaren Trends reicht dieser Effekt nicht aus, um von einem generellen Einfluss der KI-gestützten Personalisierung auf das Kaufverhalten zu sprechen. Dieser Befund steht im Kontrast zu vereinzelt Studien, die eine direkte Steigerung der Kaufintention durch personalisierte Werbung nahelegen, wie etwa Coelho et al. hervorheben (Coelho et al., 2006). Gleichzeitig deckt er sich mit differenzierteren Ansätzen, die betonen, dass Personalisierung erst unter bestimmten Bedingungen ihre volle Wirkung entfaltet.

Eine dieser Bedingungen ist die Einstellung gegenüber Datenschutz. Die Hypothesenprüfung zeigte, dass Personen mit hohen Datenschutzbedenken eine signifikant geringere Kaufabsicht aufwiesen als Personen mit niedrigen Bedenken. Die negative Korrelation zwischen Datenschutzsensibilität und Kaufabsicht betrug $r = -0,34$. Daraus lässt sich ableiten, dass die Wirkung personalisierter Werbung maßgeblich durch das Vertrauen in die datenverarbeitenden Akteure moderiert wird. Dieser Zusammenhang wurde auch von Mo et al. beschrieben, die in einem strukturgleichungsbasierten Modell aufzeigten, dass wahrgenommene Eingriffe in die Privatsphäre die positive Wirkung von Werbung abschwächen können (Mo et al., 2023, S. 4090). In diesem Zusammenhang ist auch die Studie von Boerman et al. relevant, die deutlich machen, dass Personalisierung als invasiv empfunden werden kann, wenn die Datenverarbeitung nicht transparent ist oder als unangemessen wahrgenommen wird (Boerman et al., 2021, S. 1456).

Besonders deutlich zeigt sich die Wirkung der KI-gestützten Personalisierung im Hinblick auf die Bewertung der Werbeanzeige selbst. Teilnehmer:innen bewerteten personalisierte Anzeigen signifikant positiver als nicht personalisierte. Der Mittelwert lag hier bei 4,23 im Vergleich zu 3,57. Diese affektive Reaktion spiegelt sich in den Erkenntnissen des ELM wider, das nahelegt, dass eine persönlich relevante Ansprache zu intensiverer Verarbeitung führt. In Kombination mit einem positiven emotionalen Eindruck kann dies

die Werbewirkung insgesamt verstärken. Die hohe Bewertung der personalisierten Anzeigen spricht daher für eine positive Wahrnehmung der Werbeinhalte unter der Voraussetzung einer akzeptierten Personalisierung.

Ein weiterer wichtiger Befund betrifft die wahrgenommene Relevanz der Werbung. Diese wurde in der personalisierten Bedingung signifikant höher eingeschätzt, mit einem Mittelwert von 4,38 gegenüber 3,69. Dieser Effekt bestätigt H4 und unterstreicht die Grundidee hinter personalisierter Werbung. Die Relevanz erzeugt Aufmerksamkeit, und Aufmerksamkeit ist eine Voraussetzung für Wirkungsprozesse auf kognitiver und emotionaler Ebene. Wang et al. beschreiben in ihrer Arbeit zur Kaufabsicht im Online-Kontext, dass insbesondere wahrgenommene Passung zwischen Anzeige und Nutzerinteresse ein zentraler Treiber für die Akzeptanz und Wirksamkeit von Werbung ist (Wang et al., 2023, S. e21617).

Im Rahmen der fünften Hypothese wurde außerdem der Zusammenhang zwischen der Zustimmung zur Nutzung personalisierter Werbung und Datenschutzbedenken untersucht. Auch hier bestätigte sich ein signifikanter negativer Zusammenhang mit $r = -0,42$. Je geringer die Bedenken, desto größer war die Offenheit für personalisierte Inhalte. Dieser Befund verdeutlicht, dass die Wirkung personalisierter Werbung nicht nur von inhaltlichen Faktoren abhängt, sondern auch vom übergeordneten Vertrauensverhältnis zwischen Konsumenten und werbetreibenden Unternehmen. Aus Sicht des TAM lässt sich dies so interpretieren, dass die wahrgenommene Nützlichkeit durch Datenschutzbedenken relativiert wird. Nutzer:innen wägen also ab, ob der Mehrwert der Werbung den empfundenen Kontrollverlust rechtfertigt.

Zusammengefasst zeigen die Ergebnisse, dass die Nutzung KI-gestützter Personalisierung keine allgemeine wirksame Strategie zur Steigerung der Kaufabsicht darstellt. Vielmehr erweist sich ihre Wirkung als stark kontextabhängig und durch psychologische, technologische sowie ethische Faktoren vermittelt. Die positive Wirkung auf die Bewertung der Werbeanzeige sowie auf die wahrgenommene Relevanz unterstreicht grundsätzlich das Potenzial von KI-gestützter Werbung, Inhalte individueller und passgenauer an die Zielgruppe auszurichten. Personalisierte Inhalte werden von Nutzer:innen stärker als relevant und ansprechend empfunden, was wichtige Voraussetzungen für eine positive Markenwahrnehmung und eine höhere Werbewirkung darstellt. Dennoch reichen diese affektiven Reaktionen nicht automatisch aus, um Kaufabsichten generell zu steigern. Die Ergebnisse legen nahe, dass emotionale Relevanz und kognitive Überzeugung Hand in Hand gehen müssen, um tatsächliche Kaufhandlungen anzuregen. Während Personalisierung Aufmerksamkeit und Sympathie fördern kann, scheint sie für den Schritt von positiver Wahrnehmung zu tatsächlicher Kaufintention zusätzliche Faktoren

zu benötigen, wie etwa ein attraktives Preis-Leistungs-Verhältnis, Vertrauen in die Marke sowie eine glaubwürdige Kommunikation des Mehrwerts des Produktes oder der Dienstleistung.

Besonders die starke Rolle des Datenschutzes verdeutlicht, dass technologische Möglichkeiten allein nicht ausreichen, um Konsumentenverhalten wirksam zu beeinflussen. Vielmehr zeigt sich, dass Vertrauen eine entscheidende Rahmenbedingung für die Akzeptanz personalisierter Werbung ist. Nutzer:innen wägen die wahrgenommene Relevanz einer Anzeige stets gegen ihre eigenen Datenschutzbedenken ab. Diese Ergebnisse spiegeln die wachsende Sensibilität der Verbraucher:innen gegenüber datengetriebenen Marketingpraktiken wider. Unternehmen, die auf KI-gestützte Personalisierung setzen, müssen daher nicht nur technisch versierte, sondern auch ethisch reflektierte Kommunikationsstrategien entwickeln. Transparente Information über Datenerhebung und Datenverarbeitung, klare Einwilligungsprozesse sowie eine spürbare Nutzerkontrolle über personalisierte Inhalte könnten Ansätze sein, um Vertrauen zu stärken. Darüber hinaus könnten differenzierte Personalisierungsstrategien entwickelt werden, die den Grad der Personalisierung an das individuelle Datenschutzbedürfnis der jeweiligen Nutzergruppe anpassen. Beispielsweise könnten Optionen angeboten werden, die zwischen stärker personalisierten und weniger personalisierten Varianten der Werbung wählen lassen. Auf diese Weise könnten Unternehmen einerseits die Möglichkeiten von KI-gestützter Werbung nutzen und andererseits die zunehmende Sensibilität gegenüber Datenschutz respektieren. Letztlich wird die Fähigkeit, Personalisierung nicht nur technologisch effizient, sondern auch sozial verträglich zu gestalten, ein entscheidender Erfolgsfaktor im digitalen Marketing der Zukunft sein.

6.3 Limitationen und weiterführende Forschung

Trotz sorgfältiger Konzeption und Durchführung weist die Arbeit verschiedene Limitationen auf, die bei der Interpretation der Ergebnisse berücksichtigt werden müssen. Eine zentrale Einschränkung betrifft die Zusammensetzung der Stichprobe. Obwohl die Online-Befragung eine beachtliche Anzahl an Teilnehmer:innen erreichte, war die Auswahl nicht repräsentativ für die gesamte Bevölkerung. Es überwogen jüngere Nutzer:innen mit einer hohen Affinität zu digitalen Medien, was die Generalisierbarkeit der Ergebnisse einschränken könnte. Auch die überwiegende Teilnahme von Personen mit einer erhöhten Technologieaffinität könnte dazu geführt haben, dass insbesondere Einstellungen gegenüber KI und Datenschutz verzerrt dargestellt wurden. Künftige Studien sollten daher eine breitere demografische Streuung anstreben, um differenziertere Aussagen über verschiedene Altersgruppen, Bildungsniveaus und technologische Erfahrungswerte zu

ermöglichen und dadurch ein vollständigeres Bild des Konsumverhaltens im digitalen Raum zu erhalten.

Ein weiterer limitierender Faktor liegt in der gewählten Methodik. Die Befragung setzte stark auf selbstberichtete Einschätzungen, die anfällig für Verzerrungen wie soziale Erwünschtheit oder bewusste Fehleinschätzungen sein können (Latkin et al., 2017, S. 133; Prince et al., 2008, S. 2). Insbesondere im sensiblen Bereich der Datenschutzbedenken könnte die tatsächliche Skepsis der Konsument:innen von ihren angegebenen Einstellungen abweichen. Zusätzlich könnten Missverständnisse beim Ausfüllen der Fragebögen, etwa durch unklare Formulierungen, die Validität einzelner Antworten beeinflusst haben. Zukünftige Forschung sollte deshalb alternative Erhebungsmethoden wie experimentelle Designs oder Verhaltensbeobachtungen integrieren, um ein noch authentischeres Bild des Nutzerverhaltens zu erhalten und etwaige Antwortverzerrungen zu minimieren.

Darüber hinaus war der Einsatz von Möglichkeiten generativer KI (GenAI) in dieser Arbeit begrenzt. Der verwendete Onlinefragebogen ließ keine dynamische Interaktion mit von GenAI erstellten Werbeinhalten zu. Dadurch konnten innovative Potenziale, wie die automatische Generierung personalisierter Anzeigen in Echtzeit, nicht berücksichtigt werden. Aktuelle Forschung zeigt jedoch, dass GenAI bereits in der Lage ist, vielfältige Marketinginhalte wie Texte, Bilder und Videos automatisiert zu erstellen und damit kreative Prozesse in der Werbegestaltung signifikant zu unterstützen (Grewal, Satornino, Davenport & Guha, 2024, S. 581). Solche Technologien ermöglichen eine noch stärkere Individualisierung von Werbung und könnten zu einer erhöhten wahrgenommenen Relevanz auf Seiten der Konsument:innen führen. Für zukünftige Studien erscheint es daher sinnvoll, experimentelle Designs zu entwickeln, in denen Werbeinhalte mithilfe von GenAI in Echtzeit erzeugt und in der Interaktion mit unterschiedlichen Zielgruppen getestet werden. Auf diese Weise könnten sowohl die Wahrnehmung als auch die emotionale Wirkung solcher Anzeigen realitätsnäher erfasst werden. Zudem könnten aktuelle Modelle zur Klassifikation und Auswahl generativer Systeme, wie sie von Grewal et al. vorgeschlagen werden, als methodische Grundlage zur zielgerichteten Integration von GenAI in Werbeforschung dienen.

Zudem wurde in dieser Arbeit ausschließlich die kurzfristige Wirkung von KI-gestützter Personalisierung auf Kaufabsicht und Werbewahrnehmung untersucht. Langfristige Effekte, wie etwa Veränderungen in der Markenbindung oder die Entwicklung eines Vertrauensverhältnisses zu Unternehmen, blieben unberücksichtigt. Diese Aspekte könnten jedoch entscheidend dafür sein, ob personalisierte Werbung nachhaltige Erfolge erzielt oder lediglich kurzfristige Impulse setzt. Für eine detailliertere Analyse der tatsächlichen

Auswirkungen personalisierter Werbung wäre es sinnvoll, Längsschnittstudien durchzuführen, die über mehrere Zeitpunkte hinweg Daten erheben und dabei auch Veränderungen im Konsumentenvertrauen und im Datenschutzempfinden erfassen.

Die Arbeit beschränkte sich zudem auf die Wahrnehmung und Reaktion der Konsument:innen in Bezug auf fiktive Online-Werbeanzeigen. Zwar erlaubt dieses Vorgehen eine kontrollierte Vergleichbarkeit, jedoch könnte die tatsächliche Wirkung im realen Konsumkontext variieren. In realen Kaufsituationen könnten weitere Einflussfaktoren wie situationsbedingte Gefühle, soziale Einflüsse oder zeitlicher Druck die Wirkung der Werbung modifizieren. Künftige Forschung könnte hier ansetzen und die Effekte anhand real existierender Werbekampagnen und tatsächlicher Kaufverhaltensdaten untersuchen, um eine höhere externe Validität zu erreichen.

Ein weiterer Aspekt betrifft die Dimension der Personalisierung selbst. In dieser Untersuchung wurde Personalisierung als einheitliches Konstrukt betrachtet, ohne zwischen verschiedenen Arten von Personalisierung, wie etwa produktbasiert, verhaltensbasiert oder situationsspezifisch, zu differenzieren. Unterschiedliche Formen der Personalisierung könnten jedoch unterschiedliche Auswirkungen auf die Kaufabsicht und die Werbewahrnehmung haben. Weiterführende Studien sollten diese Details stärker berücksichtigen, um genauere Aussagen darüber treffen zu können, welche Art von Personalisierung in welchen Kontexten besonders wirksam ist und welche Rolle individuelle Präferenzen oder kulturelle Unterschiede dabei spielen.

Insgesamt lässt sich festhalten, dass diese Arbeit zwar wichtige Einblicke in die Effekte der Personalisierung mittels KI ermöglicht hat, aber zugleich deutlich macht, dass weitere, tiefgehendere Analysen notwendig sind. Insbesondere die Kombination von experimentellen und longitudinalen Forschungsdesigns, eine differenziertere Betrachtung von Personalisierungsarten sowie der Einbezug realer Daten könnten dazu beitragen, das Verständnis über die komplexen Zusammenhänge zwischen Personalisierung, Datenschutzwahrnehmung und Kaufverhalten nachhaltig zu vertiefen. Darüber hinaus könnten künftige Forschungsprojekte auch die Rolle von Vertrauen in KI-Systeme und deren Einfluss auf die Akzeptanz personalisierter Werbung intensiver untersuchen.

6.4 Implikationen für die Praxis

Die Ergebnisse dieser Arbeit zeigen, dass die Nutzung KI-gestützter Personalisierung in Online-Werbeanzeigen differenzierte Auswirkungen auf das Kaufverhalten der Konsument:innen hat. Für Unternehmen ergeben sich daraus mehrere zentrale Implikationen, die bei der Gestaltung und Umsetzung von Marketingstrategien berücksichtigt werden sollten. Dabei ist insbesondere hervorzuheben, dass Personalisierungsmaßnahmen

nicht als universelles Erfolgsrezept betrachtet werden dürfen, sondern im Kontext individueller Nutzereigenschaften evaluiert werden müssen.

Erstens unterstreichen die Ergebnisse die Bedeutung einer zielgruppenspezifischen Unterscheidung. Besonders Konsument:innen mit geringer Datenschutzsensibilität zeigen eine höhere Akzeptanz gegenüber personalisierten Inhalten, was darauf hindeutet, dass Unternehmen ihre Werbemaßnahmen stärker auf diese Zielgruppe ausrichten sollten.

Zweitens wird deutlich, dass eine transparente Kommunikation über die Datennutzung eine zentrale Rolle spielt, um Vertrauen aufzubauen und die Akzeptanz personalisierter Werbung zu erhöhen. Unternehmen sollten klar und verständlich darlegen, welche Daten zu welchem Zweck verarbeitet werden und welche Vorteile Konsument:innen daraus ziehen. Dies kann beispielsweise durch interaktive Datenschutzhinweise, individualisierbare Werbeeinstellungen oder das Angebot von Opt-in-Optionen auf freiwilliger Basis umgesetzt werden.

Drittens legen die Ergebnisse nahe, dass eine übermäßige Personalisierung auch zu negativen Reaktionen führen kann. Insbesondere ist das dann der Fall, wenn Konsument:innen das Gefühl haben, manipuliert oder überwacht zu werden. Dies betrifft vor allem Nutzer:innen mit hoher Datenschutzsensibilität, bei denen personalisierte Werbung Reaktanz hervorrufen kann. Für die Praxis bedeutet dies, dass Personalisierung in einem ausgewogenen Maß eingesetzt werden sollte, um den schmalen Grat zwischen Relevanzsteigerung und Kontrollverlust nicht zu überschreiten.

Viertens bietet sich für Unternehmen die Möglichkeit, hybride Ansätze zu verfolgen, bei denen sowohl kontextuelle Informationen als auch personenbezogene Daten berücksichtigt werden. So können Streuverluste reduziert und gleichzeitig Datenschutzbedenken adressiert werden. Ein konkreter Anwendungsfall wäre die Kombination von Content-bezogener Platzierung mit einer anonymisierten Segmentierung, um relevante Inhalte auch ohne vollständige Personendaten zu liefern.

Abschließend lässt sich sagen, dass die wirksame Nutzung KI-gestützter Personalisierung eine strategische Balance zwischen technischer Effizienz, ethischer Verantwortung und psychologischer Wirkung erfordert. Unternehmen sind gefordert, nicht nur ökonomische Ziele zu verfolgen, sondern auch das Vertrauen der Konsument:innen langfristig zu sichern.

Die Ergebnisse dieser Arbeit liefern damit praxisrelevante Anhaltspunkte für die Entwicklung einer ethisch vertretbaren und wirkungsvollen Werbestrategie im digitalen Raum.

Erklärung über den Einsatz generativer KI und KI-gestützter Technologien in der Masterarbeit

Während der Vorbereitung dieser Arbeit benutzte ich ChatGPT, 4o, um ein Lektorat durchzuführen. Nach der Verwendung dieses Tools habe ich den Inhalt sorgfältig überprüft. Ich übernehme die volle Verantwortung für den Inhalt.

Literaturverzeichnis

- Adhikary, Arijit. (2014). Advertising: A Fusion Process between Consumer and Product. *Procedia Economics and Finance*, 11, 230–238. [https://doi.org/https://doi.org/10.1016/S2212-5671\(14\)00191-9](https://doi.org/https://doi.org/10.1016/S2212-5671(14)00191-9)
- Aguirre, Elizabeth, Mahr, Dominik, Grewal, Dhruv, Ruyter, Ko de & Wetzels, Martin. (2015). Unraveling the Personalization Paradox: The Effect of Information Collection and Trust-Building Strategies on Online Advertisement Effectiveness. *Journal of Retailing*, 91(1), 34–49. <https://doi.org/https://doi.org/10.1016/j.jretai.2014.09.005>
- Ajzen, Icek. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), 179–211. [https://doi.org/https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/https://doi.org/10.1016/0749-5978(91)90020-T)
- Ajzen, Icek & Sheikh, Saima. (2013). Action versus inaction: Anticipated affect in the theory of planned behavior. *Journal of Applied Social Psychology*, 43(1), 155–162. Wiley.
- Alalwan, Ali Abdullah. (2018). Investigating the impact of social media advertising features on customer purchase intention. *International Journal of Information Management*, 42, 65–77. Elsevier.
- Alhitmi, Hitmi, Mardiah, Alin, Al-Sulaiti, Khalid & Abbas, Jaffar. (2024). Data security and privacy concerns of AI-driven marketing in the context of economics and business field: an exploration into possible solutions. *Cogent Business & Management*, 11. <https://doi.org/10.1080/23311975.2024.2393743>
- Angra, Sheena & Ahuja, Sachin. (2017). Machine learning and its applications: A review. *2017 International Conference on Big Data Analytics and Computational Intelligence (ICBDAC)* (S. 57–60). <https://doi.org/10.1109/ICBDACI.2017.8070809>
- Angra, Suruchi & Ahuja, Sachin. (2017). Machine learning and its applications: A review. *International Journal of Information Technology*, 9(3), 57–63. Springer.

- Backhaus, Klaus, Erichson, Bernd, Plinke, Wulff & Weiber, Rolf. (2018). *Multivariate Analysemethoden: Eine anwendungsorientierte Einführung* (15. Auflage). Wiesbaden: Springer Gabler.
- Bashynska, Iryna. (2023). AI-Driven Personalization in Advertising: Transforming Consumer Engagement through Sustainability and Circular Economy. *Scientific Journal of Bielsko-Biala School of Finance and Law*, 27(4), 106–112. <https://doi.org/10.19192/wsfp.sj4.2023.15>
- Bélanger, France & Crossler, Robert E. (2011). Privacy in the digital age: A review of information privacy research in information systems. *MIS Quarterly*, 35(4), 1017–1042. MIS Quarterly.
- Bittner, Alvah. (2022). *Analysis-of-variance (ANOVA) Assumptions Review: Normality, Variance Equality, and Independence* (S. 33). https://doi.org/10.47461/isoes.2022_bittner
- Boerman, Sophie C. B., Kruikemeier, Sanne & Bol, Nadine. (2021). When is personalized advertising crossing personal boundaries? How type of information, data sharing, and personalized pricing influence consumer perceptions of personalized advertising. *Computers in Human Behavior Reports*, 100144. Elsevier. <https://doi.org/10.1016/j.chbr.2021.100144>
- Bruhn, Manfred. (2022). Grundbegriffe und -konzepte des Marketing. *Marketing: Grundlagen für Studium und Praxis* (S. 1–25). Wiesbaden: Springer Fachmedien Wiesbaden. https://doi.org/10.1007/978-3-658-36298-0_1
- Camilleri, Mark Anthony. (2018). Understanding Customer Needs and Wants. *Travel Marketing, Tourism Economics and the Airline Product: An Introduction to Theory and Practice* (S. 29–50). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-319-49849-2_2
- Chaffey, Dave & Ellis-Chadwick, Fiona. (2019). *Digital Marketing* (7th Edition.). Pearson Education Limited.

- Chauhan, Chetna, Parida, Vinit & Dhir, Amandeep. (2022). Linking circular economy and digitalisation technologies: A systematic literature review of past achievements and future promises. *Technological Forecasting and Social Change*, 177, 121508. <https://doi.org/10.1016/j.techfore.2022.121508>
- Coelho, P. Santos, Vilares, Manuel J. & Ball, Dwayne. (2006). Service Personalization and Loyalty. *Journal of Services Marketing*, 20(6), 391–403. Emerald. <https://doi.org/10.1108/08876040610691284>
- Collins, Christopher, Dennehy, Denis, Conboy, Kieran & Mikalef, Patrick. (2021). Artificial intelligence in information systems research: A systematic literature review and research agenda. *International Journal of Information Management*, 60, 102383. <https://doi.org/10.1016/j.ijinfomgt.2021.102383>
- Davis, Fred D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *Management Information Systems Research Center, University of Minnesota*, 13(3), 319–340. <https://doi.org/10.2307/249008>
- Demigha, Souâd. (2020). The impact of Big Data on AI. *2020 International Conference on Computational Science and Computational Intelligence (CSCI)* (S. 1395–1400). <https://doi.org/10.1109/CSCI51800.2020.00259>
- Diamantopoulos, Adamantios, Sarstedt, Marko, Fuchs, Christina, Wilczynski, Peter & Kaiser, Sebastian. (2012). Guidelines for choosing between multi-item and single-item scales for construct measurement: a predictive validity perspective. *Journal of the Academy of Marketing Science*, 40(3), 434–449. Springer. <https://doi.org/10.1007/s11747-011-0300-3>
- Dolin, Claire, Weinshel, Ben, Shan, Shawn, Hahn, Chang Min, Choi, Euirim, Mazurek, Michelle L. et al. (2018). Unpacking Perceptions of Data-Driven Inferences Underlying Online Targeting and Personalization (CHI '18). *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems* (S. 1–12). New York,

- NY, USA: Association for Computing Machinery.
<https://doi.org/10.1145/3173574.3174067>
- Dong, Yue & Peng, Chao-Ying Joanne. (2013). The prevention and handling of the missing data. *Frontiers in Psychology*, 4, 222. Frontiers Media SA.
<https://doi.org/10.3389/fpsyg.2013.00222>
- Doshi-Velez, Finale & Kim, Been. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.
- Dudhe, P. V., Kadam, N. V., Hushangabade, R. M. & Deshmukh, M. S. (2017). Internet of Things (IOT): An overview and its applications. *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)* (S. 2650–2653). <https://doi.org/10.1109/ICECDS.2017.8389935>
- Dwivedi, Yogesh K., Sharma, Anuj, Rana, Nripendra P., Giannakis, Mihalis, Goel, Pooja & Dutot, Vincent. (2023). Evolution of artificial intelligence research in Technological Forecasting and Social Change: Research topics, trends, and future directions. *Technological Forecasting and Social Change*, 192, 122579.
<https://doi.org/https://doi.org/10.1016/j.techfore.2023.122579>
- Dzyabura, Daria & Hauser, John. (2009). Active Machine Learning for Consideration Heuristics. *Marketing Science*, 30.
<https://doi.org/https://doi.org/10.1287/mksc.1110.0660>
- Field, Andy. (2018). *Discovering Statistics Using IBM SPSS Statistics* (5. Auflage). London: SAGE Publications.
- Gao, Youjiang & Liu, Hongfei. (2022a). Artificial intelligence-enabled personalization in interactive marketing: a customer journey perspective. *Journal of Research in Interactive Marketing*, 17(5), 663–680. Emerald Publishing Limited.
<https://doi.org/10.1108/JRIM-01-2022-0023>
- Gao, Youjiang & Liu, Hongfei. (2022b). Artificial intelligence-enabled personalization in interactive marketing: a customer journey perspective. *Journal of Research in Interactive Marketing*, 17, 1–18. <https://doi.org/10.1108/JRIM-01-2022-0023>

- Grewal, Dhruv, Saturnino, Cinthia B., Davenport, Thomas H. & Guha, Abhijit. (2024). How Generative AI Is Shaping the Future of Marketing. *Journal of the Academy of Marketing Science*, 52(3), 581–599. <https://doi.org/10.1007/s11747-024-01064-3>
- Gu, Chenyan, Jia, Shuyue, Lai, Jiaying, Chen, Ruli & Chang, Xinsiyu. (2024). Exploring Consumer Acceptance of AI-Generated Advertisements: From the Perspectives of Perceived Eeriness and Perceived Intelligence. *Journal of Theoretical and Applied Electronic Commerce Research*, 19(3), 2218–2238. <https://doi.org/10.3390/jtaer19030108>
- Hendrayati, Heny, Achyarsyah, Mochamad, Marimon, Frederic, Hartono, Ulil & Putit, Lennora. (2024). The Impact of Artificial Intelligence on Digital Marketing: Leveraging Potential in a Competitive Business Landscape. *Emerging Science Journal*, 8(6), 2343–2359. ESJ. <https://doi.org/10.28991/ESJ-2024-08-06-012>
- Janiesch, Christian, Zschech, Patrick & Heinrich, Kai. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. Springer. <https://doi.org/10.1007/s12525-021-00475-2>
- Jayasingh, Sudarsan, Sivakumar, Arunkumar & Vanathaiyan, Arputha Arockiaraj. (2025). Artificial Intelligence Influencers' Credibility Effect on Consumer Engagement and Purchase Intention. *Journal of Theoretical and Applied Electronic Commerce Research*, 20(1). <https://doi.org/10.3390/jtaer20010017>
- Khanfar, Ahmad A., Kiani Mavi, Reza, Iranmanesh, Mohammad & Gengatharen, Denise. (2024). Determinants of artificial intelligence adoption: research themes and future directions. *Information Technology and Management*. <https://doi.org/10.1007/s10799-024-00435-0>
- Kim, Taewook, Agarwal, Dhruv, Ackerman, Jordan & Saha, Manaswi. (2024, November 15). Steering AI-Driven Personalization of Scientific Text for General Audiences. arXiv. <https://doi.org/10.48550/arXiv.2411.09969>

- Kumar, V., Ashraf, Abdul R. & Nadeem, Waqar. (2024). AI-powered marketing: What, where, and how? *International Journal of Information Management*, 77, 102783. Elsevier. <https://doi.org/10.1016/j.ijinfomgt.2024.102783>
- Lambrecht, Anja & Tucker, Catherine. (2013). When Does Retargeting Work? Information. *Journal of Marketing*, 50(5). American Marketing Association. <https://doi.org/https://doi.org/10.1509/jmr.11.0503>
- Latkin, Carl A., Yang, Cui, Tobin, Melissa, Genao, Amy E. Roebuck, Spikes, Amy S. & Ellen, Jonathan. (2017). The relationship between social desirability bias and self-reports of health, substance use, and social network factors among urban substance users in Baltimore, Maryland. *Addictive Behaviors*, 73, 133–136. <https://doi.org/10.1016/j.addbeh.2017.05.005>
- MacKenzie, Scott, Lutz, Richard & Belch, George. (1986). The Role of Attitude toward the Ad as a Mediator of Advertising Effectiveness: A Test of Competing Explanations. *Journal of Marketing Research*, 23, 130–143. <https://doi.org/10.1177/002224378602300205>
- Mahmoudian, Mahshad, Zanjani, S. Mohammadali, Shahinzadeh, Hossein, Kabalci, Yasin, Kabalci, Ersan & Ebrahimi, Farshad. (2023). An Overview of Big Data Concepts, Methods, and Analytics: Challenges, Issues, and Opportunities. *2023 5th Global Power, Energy and Communication Conference (GPECOM)* (S. 554–559). <https://doi.org/10.1109/GPECOM58364.2023.10175760>
- Malhotra, Naresh, Kim, Sung S. & Agarwal, James. (2004). Internet users' information privacy concerns (IUIPC): The construct, the scale, and a causal model. *Information Systems Research*, 15(4).
- Masnita, Yolanda, Kasuma, Jati, Zahra, Angginta, Wilson, Nicholas & Murwonugroho, Wegig. (2024). Artificial Intelligence in Marketing: Literature Review and Future Research Agenda. *Journal of System and Management Sciences*, 14, 120–140. <https://doi.org/10.33168/JSMS.2024.0108>

- Mazgaonkar, Sahifa & Mandhare, Shital. (2024). A Study on Customers' Preference for Different Product Categories in Online Shopping and the Factors Affecting Their Online Shopping: Application of Garrett Ranking Technique. *International Journal of Advanced Research in Commerce, Management & Social Science (IJARCMSS)*, 06, 25–31.
- McCarthy, John, Minsky, Marvin L., Rochester, Nathaniel & Shannon, Claude E. (1955). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. Verfügbar unter: <https://www.formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>
- Mo, Li, Zhang, Xiaosan, Lin, Yabin, Yuan, Zhenghui & Peng, Zengjun. (2023). Consumers' Attitudes towards Online Advertising: A Model of Personalization, Informativeness, Privacy Concern and Flow Experience. *Sustainability*, 15(5), 4090. MDPI. <https://doi.org/10.3390/su15054090>
- Mühlhoff, Rainer. (2021). Predictive privacy: towards an applied ethics of data analytics. *Ethics and Information Technology*, 23(4), 675–690. <https://doi.org/10.1007/s10676-021-09606-x>
- Mühlhoff, Rainer & Willem, Theresa. (2023). Social media advertising for clinical studies: Ethical and data protection implications of online targeting. *Big Data & Society*, 10(1), 20539517231156127. <https://doi.org/10.1177/20539517231156127>
- Nagy, Szabolcs & Hajdú, Noémi. (2021). Consumer Acceptance of the Use of Artificial Intelligence in Online Shopping: Evidence From Hungary. *Amfiteatru Economic*, 23, 155–173. <https://doi.org/10.24818/EA/2021/56/155>
- Neumann, Nico, Tucker, Catherine E. & Whitfield, Timothy. (2019). Frontiers: How Effective Is Third-Party Consumer Profiling? Evidence from Field Studies. *Marketing Science*, 38(6), 918–926. <https://doi.org/https://dx.doi.org/10.2139/ssrn.3203131>
- Ngo, Thi Thuy An, Tran, Thanh Tu, An, Gia Khuong & Nguyen, Phuong Thy. (2025). Investigating the influence of augmented reality marketing application on

- consumer purchase intentions: A study in the E-commerce sector. *Computers in Human Behavior Reports*, 18, 100648. <https://doi.org/https://doi.org/10.1016/j.chbr.2025.100648>
- Nyazabe, Sllife Nyazabe, Lee, Chul Ho & Vololoniaina, Lucienne. (2025). SNS-Based Exposure Influence on Consumers' Purchasing Behavior: The Evidence from WhatsApp. *Telematics and Informatics Reports*, 100202. <https://doi.org/https://doi.org/10.1016/j.teler.2025.100202>
- Petty, Richard E. & Cacioppo, John T. (1986). The Elaboration Likelihood Model of Persuasion (Advances in Experimental Social Psychology). In Leonard Berkowitz (Hrsg.), (Band 19, S. 123–205). Academic Press. [https://doi.org/https://doi.org/10.1016/S0065-2601\(08\)60214-2](https://doi.org/https://doi.org/10.1016/S0065-2601(08)60214-2)
- Preibusch, Sören. (2013). Guide to measuring privacy concern: Review of survey and observational instruments. *International Journal of Human-Computer Studies*, 71(12), 1133–1143. <https://doi.org/https://doi.org/10.1016/j.ijhcs.2013.09.002>
- Prince, Stephanie A., Adamo, Kathleen M., Hamel, Meghan E., Hardt, Jill A., Gorber, Jodi Connor & Tremblay, Mark S. (2008). A comparison of direct versus self-report measures for assessing physical activity in adults: a systematic review. *International Journal of Behavioral Nutrition and Physical Activity*, 5(56). <https://doi.org/10.1186/1479-5868-5-56>
- Rawat, Danda B., Doku, Ronald & Garuba, Moses. (2021). Cybersecurity in Big Data Era: From Securing Big Data to Data-Driven Security. *IEEE Transactions on Services Computing*, 14(6), 2055–2072. <https://doi.org/10.1109/TSC.2019.2907247>
- Saura, José, Škare, Vatroslav & Ozretić Došen, Đurđana. (2024). Is AI-based digital marketing ethical? Assessing a new data privacy paradox. *Journal of Innovation & Knowledge*, 9, 100597. <https://doi.org/10.1016/j.jik.2024.100597>
- Sawyer, Steven. (2009). Analysis of Variance: The Fundamental Concepts. *Journal of Manual & Manipulative Therapy*, 17, 27E-38E. <https://doi.org/10.1179/jmt.2009.17.2.27E>

- Schecker, Horst. (2014). Überprüfung der Konsistenz von Itemgruppen mit Cronbachs alpha.
- Shapiro, Samuel Sanford & Wilk, Martin B. (1965). An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, 52(3/4), 591–611. Oxford University Press on behalf of Biometrika Trust. <https://doi.org/10.2307/2333709>
- Shinde, Pramila P. & Shah, Seema. (2018). A Review of Machine Learning and Deep Learning Applications. *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)* (S. 1–6). <https://doi.org/10.1109/ICCUBEA.2018.8697857>
- Statista. (2023). Online advertising spending worldwide from 2007 to 2024. Verfügbar unter: <https://www.statista.com/statistics/237974/online-advertising-spending-worldwide/>
- Sutton, Richard S. & Barto, Andrew G. (2018). *Reinforcement Learning: An Introduction* (2. Auflage). Cambridge, MA: MIT Press.
- Taber, Keith S. (2018). The Use of Cronbach's Alpha When Developing and Reporting Research Instruments in Science Education. *Research in Science Education*, 48(6), 1273–1296. Springer. <https://doi.org/10.1007/s11165-016-9602-2>
- Trawnih, Ali, al masaeed, Sultan, Alsoud, Malek & Alkufahy, Amer. (2022). Understanding artificial intelligence experience: A customer perspective. *International Journal of Data and Network Science*, 6, 1471–1484. <https://doi.org/10.5267/j.ijdns.2022.5.004>
- Tuten, Tracy L. & Solomon, Michael R. (2021). *Social Media Marketing* (4th Edition.). Sage Publications.
- Verma, Sanjeev, Sharma, Rohit, Deb, Subhamay & Maitra, Debojit. (2021). Artificial intelligence in marketing: Systematic review and future research direction. *International Journal of Information Management Data Insights*, 1, 100002. <https://doi.org/10.1016/j.jjime.2020.100002>

- Wang, Chenggang, Liu, Tiansen, Zhu, Yue, Wang, He, Wang, Xinyu & Zhao, Shunyao. (2023). The influence of consumer perception on purchase intention: Evidence from cross-border E-commerce platforms. *Heliyon*, 9(11), e21617. <https://doi.org/https://doi.org/10.1016/j.heliyon.2023.e21617>
- Wang, Y., Chen, S. & Li, X. (2024). An elaboration likelihood model of sales performance in live commerce. *Journal of Retailing and Consumer Services*, 76, 102514. Elsevier. <https://doi.org/10.1016/j.jretconser.2024.102514>
- Wiktor, Jan W. & Sanak-Kosmowska, Katarzyna. (2021). The Competitive Function of Online Advertising. An Empirical Evaluation of Companies' Communication Strategies in a Digital World. *Procedia Computer Science*, 192, 4158–4168. <https://doi.org/10.1016/j.procs.2021.09.191>
- Wolff, Hans-Georg & Bacher, Johann. (2010). Hauptkomponentenanalyse und explorative Faktorenanalyse. *Handbuch der sozialwissenschaftlichen Datenanalyse*. https://doi.org/10.1007/978-3-531-92038-2_15
- Yuan, Yong, Wang, Feiyue, Li, Juanjuan & Qin, Rui. (2014). A survey on real time bidding advertising. *Proceedings of 2014 IEEE International Conference on Service Operations and Logistics, and Informatics* (S. 418–423). <https://doi.org/10.1109/SOLI.2014.6960761>
- Zhang, L., Liu, H. & Huang, M. (2024). AI Meets the Shopper: Psychosocial Factors in Ease of Use and Adoption of AI in E-Retail. *Frontiers in Psychology*, 15, 11273900. Frontiers Media. <https://doi.org/10.3389/fpsyg.2024.11273900>
- Zhang, L. & Zhao, X. (2023). Research on Social Media Advertising Persuasion Based on the Elaboration Likelihood Model. *SHS Web of Conferences*, 163, 01002. EDP Sciences. <https://doi.org/10.1051/shsconf/202316301002>
- Zhao, Y., Chen, X. & Singh, R. (2023). An Empirical Evaluation of Technology Acceptance Model for Artificial Intelligence in E-Commerce. *Heliyon*, 9(11), e12600. Elsevier. <https://doi.org/10.1016/j.heliyon.2023.e18349>

Ziegenfuss, Jeanette, Easterday, Casey, Dinh, Jennifer, JaKa, Meghan, Kottke, Thomas & Canterbury, Marna. (2021). Impact of demographic survey questions on response rate and measurement: A randomized experiment. *Survey Practice*, 14, 1–11. <https://doi.org/10.29115/SP-2021-0010>

Abbildungsverzeichnis

<i>Abbildung 1:</i> Anzahl der AI-relevanten, publizierten Artikel bis zum Jahr 2022.....	1
<i>Abbildung 2:</i> Einschätzung polnischer Unternehmen zur wettbewerbsbezogenen Funktion von Online-Werbung.	7
<i>Abbildung 3:</i> Die Visualisierung des Technology Acceptance Model.	14
<i>Abbildung 4:</i> Entwicklung der jährlichen Anzahl von Veröffentlichungen zur KI-Adoption zwischen 1984 und 2022.	20
<i>Abbildung 5:</i> Beispiele für den exponentiellen Wachstum von Daten.	23
<i>Abbildung 6:</i> Darstellung des 4V-Modells und der zentraler Nutzen von Big Data für Unternehmen.	24
<i>Abbildung 7:</i> Das Interface von Translider.	26
<i>Abbildung 8:</i> Das KI-gesteuerte Customer-Experience-Model.	27
<i>Abbildung 9:</i> Visuelle Darstellung des Netzwerkes von wissenschaftlichen Arbeiten in Marketing.	29
<i>Abbildung 10:</i> Beispielabfrage von Autos mit Konfigurationen.	30
<i>Abbildung 11:</i> Visualisierung des „Predictive Model“, das sensible Informationen generiert.	32
<i>Abbildung 12:</i> Oberfläche zum Hochladen von Kundendateien.	33
<i>Abbildung 13:</i> Kontrollfluss im Fragebogen.	40
<i>Abbildung 14:</i> Verteilung der Bewertungen zur Werbewirkung (Passung zu Interessen, Ansprechbarkeit und Kaufwahrscheinlichkeit) nach Gruppen.	57
<i>Abbildung 15:</i> Boxplots der Einschätzungen zur Ansprechbarkeit der Werbung und zur Kaufwahrscheinlichkeit des beworbenen Produkts in Abhängigkeit vom Besorgnisgrad über den Schutz persönlicher Daten im Internet.	59
<i>Abbildung 16:</i> Boxplots zur Verteilung der Werbewahrnehmung in Abhängigkeit vom Gefühl ungewollter Datenverwendung.	61
<i>Abbildung 17:</i> Boxplots der Einschätzungen zur Passung der Werbung zu den eigenen Interessen, zur Ansprechbarkeit der Werbung sowie zur Kaufwahrscheinlichkeit des beworbenen Produkts in Abhängigkeit vom Besorgnisgrad über den Schutz persönlicher Daten im Internet.	63

Abbildung 18: Boxplots zur Verteilung der Bewertungen dreier
Werbewahrnehmungsaspekte in Abhängigkeit vom Interesse an Online-Werbung.66

Tabellenverzeichnis

Tabelle 1 Zusammenfassung der Modelle	19
Tabelle 2 Zuordnung der Fragen zu den jeweiligen Hypothesen	41
Tabelle 3 Verteilung der Teilnehmerinnen auf Altersgruppen	43
Tabelle 4 Verteilung der Teilnehmerinnen auf Geschlechter	43
Tabelle 5 Verteilung der höchsten Bildungsabschlüsse von Teilnehmer:innen	44
Tabelle 6 Die Anzahl der Häufigkeit der Onlinekäufe von Teilnehmer:innen.....	44
Tabelle 7 Interesse an Online-Werbung	45
Tabelle 8 Überprüfung der Konsistenz von Itemgruppen mit Cronbachs α	46
Tabelle 9 Kodierungen der Gruppenzuordnungen von Proband:innen	48
Tabelle 10 Zuordnung der Einzelfragen zu den gebildeten Skalen „Werbeakzeptanz“ und „Datenschutzbedenken“	49
Tabelle 11 Höchste Faktorladungen mit zugeordnetem Faktor pro Frage	49
Tabelle 12 Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H1	51
Tabelle 12 Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H2	52
Tabelle 14 Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H3	53
Tabelle 15 Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H4	54
Tabelle 16 Ergebnis des Shapiro-Wilk-Tests für die Überprüfung von H5	55
Tabelle 17 ANOVA für die Hypothesenüberprüfung von H1	58
Tabelle 18 ANOVA für die Hypothesenüberprüfung von H2	60
Tabelle 19 ANOVA für die Hypothesenüberprüfung von H3	62
Tabelle 20 ANOVA für die Hypothesenüberprüfung von H4.	64
Tabelle 21 ANOVA für die Hypothesenüberprüfung von H5	67
Tabelle 22 Einfluss ausgewählter Wahrnehmungsdimensionen auf die Kaufwahrscheinlichkeit.....	69
Tabelle 23 Einfluss ausgewählter Wahrnehmungsdimensionen auf die Kaufwahrscheinlichkeit.....	70
Tabelle 24 Zusammenfassung der Hypothesenüberprüfungen	75

Anhang

Herzlich willkommen und vielen Dank für Ihre Teilnahme an dieser Studie!

Diese Umfrage ist Teil einer wissenschaftlichen Untersuchung zum Thema **personalisierte vs. nicht-personalisierte Online-Werbung**. Ziel der Studie ist es, die Wahrnehmung und Wirkung unterschiedlicher Werbeformen auf das Kaufinteresse von Verbraucher:innen zu untersuchen.

Ihre Teilnahme ist vollständig anonym und alle erhobenen Daten werden ausschließlich für wissenschaftliche Zwecke verwendet. Die Beantwortung der Fragen dauert etwa **5–10 Minuten**.

Ablauf der Umfrage

- Sie werden zu Beginn einige Fragen zu Ihrem Einkaufsverhalten beantworten.
- Anschließend sehen Sie verschiedene Produktangebote und geben an, ob Sie Interesse an diesen haben.
- Basierend auf Ihren Antworten wird Ihnen am Ende eine Werbeanzeige angezeigt.
- Abschließend beantworten Sie einige Fragen zur Wahrnehmung der Werbung.

Hinweis: Die in dieser Umfrage gezeigten Bilder wurden mit Hilfe von **künstlicher Intelligenz generiert**.

Die Teilnahme an der Studie ist **freiwillig**, und Sie können die Umfrage jederzeit ohne Angabe von Gründen abbrechen. Falls Sie Fragen haben oder weitere Informationen zur Studie wünschen, können Sie uns unter **sophie.steurer@mail.fernfh.ac.at** kontaktieren.

Mit Ihrer Teilnahme leisten Sie einen wertvollen Beitrag zur Forschung! Vielen Dank für Ihre Unterstützung!

Einverständniserklärung zur Teilnahme an der Studie

Vielen Dank für Ihr Interesse an dieser wissenschaftlichen Studie. Bevor Sie teilnehmen, möchten wir Sie über wichtige Aspekte der Untersuchung informieren.

Zweck der Studie

Diese Studie untersucht die Wahrnehmung und Wirkung unterschiedlicher Online-Werbeformen. Ihre Teilnahme hilft uns, wertvolle wissenschaftliche Erkenntnisse zu gewinnen.

Freiwilligkeit und Datenschutz

- Die Teilnahme ist **freiwillig**, und Sie können die Umfrage jederzeit ohne Angabe von Gründen abbrechen.
- Alle erhobenen Daten werden **anonymisiert** gespeichert und ausschließlich für wissenschaftliche Zwecke verwendet.
- Es werden **keine personenbezogenen Daten** wie Name oder E-Mail-Adresse erfasst.
- Die Datenverarbeitung erfolgt gemäß den geltenden Datenschutzrichtlinien (DSGVO).

Falls Sie Fragen zu dieser Studie haben, können Sie uns jederzeit unter **sophie.steurer@mail.fernfh.ac.at** kontaktieren.

Mit dem Klick auf „Weiter“ bestätigen Sie, dass Sie die oben genannten Informationen gelesen haben und freiwillig an der Studie teilnehmen möchten.

Im Rahmen dieser Umfrage werden personenbezogene Daten erfasst und gespeichert. Dies erfolgt ausschließlich zu Zwecken der Auswertung und Analyse der Umfrageergebnisse. Die Verarbeitung der Daten erfolgt unter Beachtung der geltenden Datenschutzbestimmungen. Ihre Daten werden vertraulich behandelt und nicht an unbefugte Dritte weitergegeben.

Mit Ihrer Teilnahme an der Umfrage erklären Sie sich mit der Speicherung und Verarbeitung Ihrer Daten einverstanden.

Wie alt sind Sie?

☐ 18–24 Jahre

☐ 25–34 Jahre

☐ 35–44 Jahre

☐ 45–54 Jahre

☐ 55–64 Jahre

☐ 65 Jahre oder älter

☐ Keine Angabe

Wie würden Sie Ihr Geschlecht beschreiben?

☐ Männlich

☐ Weiblich

☐ Divers

☐ Möchte ich nicht angeben

Welchen höchsten Bildungsabschluss haben Sie erreicht?

- ☐ Keinen Schulabschluss
- ☐ Hauptschulabschluss
- ☐ Mittlere Reife (Realschulabschluss)
- ☐ Fachabitur
- ☐ Allgemeine Hochschulreife (Abitur)
- ☐ Berufsausbildung (ohne Studium)
- ☐ Bachelor-Abschluss
- ☐ Master-Abschluss oder höher
- ☐ Promotion (Dr./PhD)
- ☐ Möchte ich nicht angeben

Wie häufig kaufen Sie online ein?

- ☐ Häufig (mehrmals pro Monat)
- ☐ Gelegentlich (einmal pro Monat oder seltener)
- ☐ Selten (weniger als 5-mal pro Jahr)
- ☐ Nie

Wie häufig kaufen Sie online ein?

- ☐ Häufig (mehrmals pro Monat)
- ☐ Gelegentlich (einmal pro Monat oder seltener)
- ☐ Selten (weniger als 5-mal pro Jahr)
- ☐ Nie

Wie interessiert sind Sie an Online-Werbung? (1 = überhaupt nicht interessiert, 5 = sehr interessiert)

1

☐

2

☐

3

☐

4

☐

5

☐

Welche der folgenden Produktkategorien interessieren Sie besonders? (Wählen Sie mindestens 3 Produktkategorien)

☐ Smartphones

☐ Laptops

☐ Smartwatches

☐ Lebensmittel & Getränke

☐ Kamera

☐ Film & Musik

☐ Tablets

☐ Kosmetik

Wie besorgt sind Sie über den Schutz Ihrer persönlichen Daten im Internet?

☐ 1 – Überhaupt nicht besorgt

☐ 2 – Wenig besorgt

☐ 3 – Neutral

☐ 4 – Eher besorgt

☐ 5 – Sehr besorgt

Smartphone



Laptop



Smartwatches



Lebensmittel & Getränke



Kamera



Film & Musik



Tablets



Kosmetik

Schönheit, die natürlich strahlt



Hochwertige Pflege für gesunde Haut
Sanfte Formeln für ein frisches Hautgefühl
Make-up, das deine natürliche Schönheit unterstreicht
Strahle mit Selbstbewusstsein – jeden Tag!

Wasserfilter

Reines Wasser. Reines Leben.

Erleben Sie die Frische eines hochwertigen Wasserfilters direkt



Wie gut passt die gezeigte Werbung zu Ihren Interessen?

☐ 1 – Überhaupt nicht passend

☐ 2 – Wenig passend

☐ 3 – Neutral

☐ 4 – Eher passend

☐ 5 – Sehr passend

Wie ansprechend finden Sie diese Werbung?

☐ 1 – Überhaupt nicht ansprechend

☐ 2 – Wenig ansprechend

☐ 3 – Neutral

☐ 4 – Eher ansprechend

☐ 5 – Sehr ansprechend

Wie wahrscheinlich ist es, dass Sie dieses Produkt aus der Werbung kaufen würden? (1 = sehr unwahrscheinlich 5 = sehr wahrscheinlich)

1



2



3



4



5



Wie vertrauenswürdig finden Sie diese Werbung?

☐ 1 – Überhaupt nicht vertrauenswürdig

☐ 2 – Wenig vertrauenswürdig

☐ 3 – Neutral

☐ 4 – Eher vertrauenswürdig

☐ 5 – Sehr vertrauenswürdig

Machen Sie sich Sorgen darüber, wie die Werbung Ihre Interessen erkannt hat?

☐ 1 – Überhaupt nicht besorgt

☐ 2 – Wenig besorgt

☐ 3 – Neutral

☐ 4 – Eher besorgt

☐ 5 – Sehr besorgt

Inwiefern hatten Sie das Gefühl, durch die gezeigte Werbung überwacht zu werden?

☐ 1 – Überhaupt nicht überwacht

☐ 2 – Kaum überwacht

☐ 3 – Neutral

☐ 4 – Eher überwacht

☐ 5 – Sehr stark überwacht

Haben Sie das Gefühl, dass Ihre persönlichen Daten ohne Ihr Wissen für diese Werbung verwendet wurden?

☐ 1 – Überhaupt nicht

☐ 2 – Kaum

☐ 3 – Neutral

☐ 4 – Eher ja

☐ 5 – Ja, sehr stark

Wie sehr sind Sie über Datenschutz besorgt?

☐ 1 – Überhaupt nicht besorgt

☐ 2 – Kaum besorgt

☐ 3 – Neutral

☐ 4 – Eher besorgt

☐ 5 – Sehr besorgt