

PraxisWisser

GERMAN JOURNAL OF MARKETING®

KI • KÜNSTLICHE INTELLIGENZ • PRODUCT DESIGN • AI • ARTIFICIAL INTELLIGENCE DIGITALISIERUNG • LARGE LANGUAGE MODELS • GENERATIVE AI • BIG DATA • INFLUENCER MARKETING • VIRTUAL ROBOTER • MARKETING ANALYTICS • BIG DATA • EMPFEHLUNG ALGORITHMUS DIGITAL MARKETING • INFLUENCER MARKETING • VIRTUAL INFLUENCER BOTS • MARKETING ANALYTICS • ROBOTER TRANSFORMATION • GENERATIVE AI EMPFEHLUNG ALGORITHMUS • BIG DATA VIRTUAL INFLUENCER • BOTS • KI • AI



Künstliche Intelligenz (KI) im Marketing

Heft 01/2024
ISSN 2509-3029

AfM
Arbeitsgemeinschaft
für Marketing

PraxisWisser

GERMAN JOURNAL OF MARKETING®

Künstliche Intelligenz (KI) im Marketing

PraxisWisser GERMAN JOURNAL OF MARKETING®

Organ der Arbeitsgemeinschaft für Marketing (AfM)

<http://arbeitsgemeinschaft.marketing/praxiswissen-marketing>

ISSN 2509-3029 Heft 01/2024

Herausgeber*innen im Auftrag der AfM:

Prof. Dr. Mahmut Arica

FOM Hochschule für Oekonomie & Management
Martin-Luther-King-Weg 30-30a
D-48155 Münster
mahmut.arica@fom.de

Prof. Dr. Annett Wolf

Hochschule für Technik und Wirtschaft Berlin (HTW)
Treskowallee 8
D-10318 Berlin
annett.wolf@htw-berlin.de

Herausgeberbeirat:

Prof. Dr. Matthias Johannes Bauer (IST Düsseldorf) | **Prof. Dr. Andrea Bookhagen** Hochschule für Technik und Wirtschaft Berlin (HTW) | **Prof. Dr. Monika Gerschau** (HS Weihenstephan-Triesdorf) | **Prof. Dr. Annette Hoxtell** (FH Erfurt) | **Prof. Dr. Karsten Kilian** (HS für angewandte Wissenschaften Würzburg-Schweinfurt) | **Prof. Dr. Ingo Kracht** (TH Ostwestfalen-Lippe) | **Prof. Dr. Alexander Magerhans** (Ernst-Abbe-Hochschule Jena) | **Prof. Dr. Annette Pattloch** (Berliner Hochschule für Technik) | **Prof. Dr. Jörn Redler** (HS Mainz) | **Prof. Dr. Hendrik Send** Hochschule für Technik und Wirtschaft Berlin (HTW) | **Prof. Dr. Marcus Stumpf** (FOM Hochschule für Oekonomie & Management)

Cover-Gestaltung: Vanessa van Anken | www.vananken.design

Vorwort

Kaum eine andere Disziplin in der Betriebswirtschaft zeichnet sich aktuell durch einen so starken **Veränderungsprozess** aus wie das Marketing. So schafft das Thema **Künstliche Intelligenz (KI)** bspw. neue Anwendungsmöglichkeiten bei der **Datenanalyse** und **Kundeninteraktion**. Durch den Einsatz von KI können Unternehmen große Datenmengen effizient analysieren, was eine effektivere **Zielgruppenansprache** und eine **Optimierung der Kundenbindung** ermöglicht. Darüber hinaus automatisiert KI routinemäßige Aufgaben im Marketing, wodurch Ressourcen für **strategische und kreative Aufgaben** freigesetzt werden.

Es ist daher nicht überraschend, dass KI die aktuelle **Diskussion in Wissenschaft und Praxis** bestimmt. In der Ausgabe 01/2024 der **PraxisWissen Marketing** gibt die Marketingcommunity **Antworten auf die Frage** nach **innovativen Ansätzen, Methoden und Techniken bei der Anwendung von KI im Marketing**.

Das enorme **Potenzial** dieser Technologie verdeutlicht der erste Beitrag, welcher weitestgehend mit KI generiert wurde. Eine **automatisierte Analyse von 344 Abstracts als Literatur Review** zeigt aktuelle **Forschungstrends** zu KI im Marketing.

Die **Marktforschungscommunity** diskutiert die zukünftige Relevanz von KI bei der Informationsbeschaffung und -verarbeitung. KI-gestützte Systeme analysieren Datenmengen in Echtzeit, was **nachfragerbezogene Analysen im Marketing** und personalisierte Kundenerlebnisse ermöglicht. So helfen bspw. **KI-basierte Empfehlungsalgorithmen** Prognosemodelle über das Konsumverhalten zu erstellen und die Kundenbindung zu optimieren. Andere Autorinnen und Autoren gehen einen Schritt weiter und untersuchen, wie sich die **Wahrnehmung** und **Akzeptanz** beispielsweise beim **Einsatz virtueller Influencer** auf Kundenseite verhält.

Unabhängig davon ist auf der Ebene des **operativen Marketing** zu hinterfragen, wie **Content-Marketing-Strategien durch den Einsatz von KI optimiert** werden können. Ein Beitrag diskutiert auch, wie **KI in den Produktentwicklungsprozess** integriert werden kann und welche Auswirkungen dies **auf die Konsumenten** hat. Letztendlich widmet sich ein Beitrag auch dem **Vergleich zwischen einer traditionell erarbeitete Marketingstrategie** mit einer parallel dazu durch **KI-generierten Marketingstrategie**. Die **Unterschiede werden kenntlich gemacht, kommentiert und bewertet**.

Diese vorliegende **neunte Auflage der PraxisWissen Marketing** ist die letzte in bisheriger Form. Künftig wird sie als **Buchreihe im Springer Gabler Verlag** erscheinen, womit wir als **Arbeitsgemeinschaft für Marketing (AfM)** eine deutlich höhere **Verbreitung** und einen intensiveren **praxis-wissenschaftlichen Diskurs** erhoffen. Der **Call for Papers** für die kommende Ausgabe unter dem Titel "**Customer Centricity**" ist auf S. 142 ff. angehängt.

Das Herausgeberduo **bedankt sich herzlich** bei den **Autorinnen und Autoren** dieser Ausgabe, den **Mitgliedern des Herausgeberbeirats**, die das **Blind Review** der Beiträge übernahmen, sowie allen Unterstützern dieser Zeitschrift. Wir wünschen eine spannende Lektüre und interessante Einblicke in das Thema **KI im Marketing**.

Münster und Berlin im Mai 2024
Mahmut Arica & Annett Wolf

Inhalt

- 6 Künstliche Intelligenz trifft Marketing: Ein generativer Review-Ansatz zur Analyse aktueller Forschungstrends**
- Rüdiger Buchkremer
- 34 Interdisziplinäre Anwendung des Supervised Machine Learning für nachfragerbezogene Analysen im Marketing**
- Manuel Muth
Gerd Nufer
- 53 Funktionsweise und Wirkung KI-basierter Empfehlungsalgorithmen am Beispiel von Spotify**
- Annette Hoxtell
Katharina Veit
- 72 Consumers' perceptions and acceptance of virtual influencers on social media**
- Doris Berger-Grabner
Tobias Dürhammer
- 85 Optimising content-based online marketing strategies through generative AI: In-sights, algorithms, and future perspectives**
- Oksana Deriabina
Christina Hofmann-Stölting
Stefan Tuschl
- 103 Generative AI in Product Design: Investigating the effects of AI creatorship disclosure on consumer responses**
- Julia Peter
Stefanie Wannow
Martin Haupt
- 124 Generative Künstliche Intelligenz im Marketing: Strategien zur Neuausrichtung in der Marketing-Kommunikation (MarKom)**
- Isabelle Rottmann
Sandra Gronover
Martina Mitterhofer
- 142 Call for Papers Customer Centricity: Grundlagen und Anwendungsfälle in der kundenorientierten Unternehmensführung**
- Mahmut Arica
Annett Wolf

Interdisziplinäre Anwendung des Supervised Machine Learning für nachfragerbezogene Analysen im Marketing

Manuel Muth, Gerd Nufer

This conceptual paper synthesizes the state-of-the-art knowledge at the intersection of consumer-related marketing analytics and Supervised Machine Learning. The article discusses the principles and systematization of this area and identifies practical requirements coming from both disciplines. It includes marketing-specific application criteria for Supervised Machine Learning, general technical prerequisites, and strategies for creating model transparency. Also, relevant limitations, such as potential biases in consumer data, are explored. Thus, the findings contribute to a differentiated understanding of key aspects to be considered in this interdisciplinary marketing field.

Der konzeptionelle Beitrag gibt einen Überblick über den Stand der Forschung zum Einsatz des Supervised Machine Learning im Kontext von nachfragerbezogenen Marketinganalysen. Der Artikel befasst sich dabei mit dem Funktionsprinzip und der Systematisierung dieses Gebiets und identifiziert Praxisanforderungen aus beiden Fachrichtungen. Diskutiert werden etwa marketingspezifische Anwendungsvoraussetzungen für das Supervised Machine Learning, technische Rahmenbedingungen sowie Methodiken zur Erzeugung von Modelltransparenz. Ebenso werden dahingehende Limitationen erörtert, beispielsweise mögliche Verzerrungen in Nachfragerdaten. Die Untersuchungsergebnisse leisten so einen Beitrag für ein differenziertes Verständnis des Anforderungsspektrums im analysierten interdisziplinären Anwendungsgebiet.

Manuel Muth, M.A., ist Manager für Forecasting Data Analytics und Alumnus der ESB Business School, wo er 2021 als Jahrgangsbester das Masterprogramm International Retail Management abschloss. Sein Forschungsschwerpunkt liegt im Einsatz des Machine Learning für Marketingprognosen und strategische Managemententscheidungen.

Prof. Dr. Gerd Nufer lehrt Betriebswirtschaftslehre mit den Schwerpunkten Marketing, Handel und Sportmanagement an der ESB Business School der Hochschule Reutlingen. Er ist Studiendekan des MBA International Management Part-Time sowie Akademischer Leiter des berufsbegleitenden M.A. International Retail Management. Seine Lehr-, Forschungs- und Beratungsschwerpunkte sind Sport- und Event-Marketing, Sponsoring / Ambush Marketing, Marketing-Kommunikation, Marketing below the line / innovatives Marketing sowie internationale Marktforschung.

1. Einleitung

Auf der Grundlage ihrer Forschungsergebnisse beschreiben Huang; Rust (2021, S. 30): „**Artificial intelligence (AI)** in marketing is currently gaining importance, due to increasing computing power, lower computing costs, the availability of big data, and the advance of Machine Learning algorithms“. Nach Auffassung von Halfmann (2022, S. 4) führen derartige Entwicklungen zu einem Wandel der akademischen Sichtweise auf die Disziplin des Marketing. So verschiebe sich der Schwerpunkt in der Praxis zunehmend von der Informationsbeschaffung zu einer zielgerichteten Aufbereitung und Nutzung von Daten. In diesem Kontext, in dem der Komplexität der Marketingsachverhalte mit traditionellen quantitativen Analysen oder manuellen Verarbeitungsprozessen nur unzureichend zu begegnen ist, bietet das Machine Learning ein erweitertes Spektrum an Handlungsoptionen (vgl. Birim et al., 2022, S. 3; Kharfan et al., 2021, S. 161).

Dabei fokussiert sich die Betrachtung auf die Anwendung von Verfahren des Machine Learning in überwachter Form, bekannt als **Supervised Machine Learning (SML)**, und untersucht deren interdisziplinären Einsatz im Marketing, insbesondere für Analysen in einem nachfragerbezogenen Kontext. Der nachfolgende Artikel ist dafür methodisch als konzeptioneller Forschungsbeitrag angelegt. Er soll den bestehenden wissenschaftlichen Erkenntnisbestand speziell für den fachübergreifenden Rahmen zwischen Marketing und SML zusammenführen und erörtern. Mit Blick auf den fachübergreifenden Kontext wird dies mittels einer Analyse des Funktionsprinzips von Machine Learning (2), einer Systematisierung der Subdisziplin des SML (3) sowie einer Diskussion der spezifischen Anforderungen des Marketing (4.1) und des SML (4.2) veranschaulicht. Das bildet die Grundlage, um in diesem Spannungsfeld den praktischen Nutzen herzuleiten und um mögliche Limitationen und Herausforderungen (5) darzustellen. Abschließend werden die Ergebnisse in einem Fazit (6) zusammengefasst. Diese tragen zum gegenwärtigen akademischen Diskurs bei, indem sie ein Verständnis für die Komplexität und Anforderungen vermitteln, das SML bei der **interdisziplinären Marketinganwendung** erfordert, um leistungsfähige Analysen für die Praxis zu liefern.

2. Funktionsprinzip des Machine Learning

Das Machine Learning zeichnet sich – im weitesten Sinne – durch die Lösung komplexer Fragestellungen anhand von Daten aus, oder wie Black et al. (2023, S. 200) es beschreiben: „ML [Machine Learning] describes the automated process of identifying (“learning”) patterns in data to perform tasks“. Hierbei werden u.a. systematisch Muster und Beziehungen in Datensätzen identifiziert, um daraus verallgemeinerbares Wissen abzuleiten (vgl. Birim et al., 2022, S. 6; Homburg, 2020, S. 273). Dieser Ansatz gilt als besonders wirksam beim Extrahieren relevanter Informationen aus sehr großen oder komplexen Datensätzen, was eine rein manuelle Erfüllung kaum zulässt (vgl. Kharfan et al., 2020, S. 3; Pavlyshenko, 2019, S. 1 ff.). In einer gängigen Definition interpretiert Mitchell (1997, S. 2) diese Systematik als das **Lernen aus Erfahrung**, die darauf abzielt, eine bestimmte Lernaufgabe mit einem höheren Leistungsmaß zu erfüllen. In der Marketingpraxis bedeutet dies, mit Machine Learning z.B. aus einer Vielzahl online

verfügbarer Text-, Bild- oder Videodaten nachfragerbezogene Präferenzen zu identifizieren, eine personalisierte Preisgestaltung zu generieren, individualisierte Produktempfehlungen auszusteuern oder Reaktionen von Nachfragern auf Werbestimuli zu projizieren (vgl. Proserpio et al., 2020, 393 ff.). Darüber hinaus lässt sich das Machine Learning dazu verwenden, zukünftige Käuferfolge (Conversion) bereits in einem frühen Stadium anhand von Nachfragerdaten zu prognostizieren, um den Umfang potenzieller Werbemaßnahmen zu steuern (vgl. Karthik et al., 2020, S. 510 ff.).

Im Hinblick auf die Abgrenzung zu Künstlicher Intelligenz (KI) beobachtet die Fraunhofer-Gesellschaft (2018, S. 6), dass „insbesondere im ökonomischen Kontext KI und Machine Learning oft synonym verwendet werden“. Allerdings wird gleichzeitig hervor gehoben, dass der Gegenstand des KI-Begriffs sehr weit definiert werde. So zählen hierzu die Ausführung intelligenter Aufgaben und Verhaltensweisen durch Maschinen, wobei das Machine Learning als relevanter Teilbereich (vgl. Mariani et al., 2021, S. 759) und teilweise sogar als „**Schlüsseltechnologie**“ (Bundesministerium für Wirtschaft und Energie, 2020, S. 4) verstanden wird.

Als ein wesentliches Unterscheidungskriterium des Machine Learning wird u.a. angeführt, dass Modelle dabei nicht durch eine explizite Programmieranweisung, sondern durch ein Lernverfahren unmittelbar aus den Datenmengen erzeugt werden (vgl. Lanquillon, 2019, S. 89 ff.; Mariani et al., 2021, S. 759; Verma et al., 2021, S. 2). Birim et al. (2022, S. 6) verweisen hier auf die umfangreiche Modellierungsleistung und die Vorteile der auf diese Weise erzeugten, nicht-linearen Strukturen. Smirnov; Huchzermeier (2020, S. 671) unterstreichen darüber hinaus das Charakteristikum, dass „a Machine Learning model captures interactions in high-dimensional data without requiring that a particular functional relationship be specified a priori“. Ein zentraler Mehrwert des Machine Learning liegt somit darin, dass dort fortgeschrittene Methoden im Voraus oft gar keine oder nur geringe Annahmen über funktionale Zusammenhänge benötigen (vgl. auch: Castán-Lascorz, 2022, S. 613).

Das breite Forschungsinteresse zeigt sich in einer Reihe umfassender Übersichtsarbeiten, die sich dediziert mit der Ermittlung zentraler Einsatzbereiche sowie mit existierenden Trendfeldern im Marketing befassen – wie etwa durch Mustak et al. (2021, S. 389 ff.), Mariani et al. (2021, S. 755 ff.) oder Vlačić et al. (2021, S. 187 ff.) belegt. Mariani et al. (2021, S. 769) kommen dabei u.a. zu dem Schluss: „Evidence suggest that some marketing activities could be outperformed by automated systems relying on Machine Learning“.

3. Systematisierung von SML

Innerhalb des Machine Learning weist das SML bei der **praktischen Anwendung** einen sehr hohen Verbreitungsgrad auf (vgl. Luu, 2018, S. 332; Welsch et al., 2018, S. 371). Dabei ist ML in weitere Unterkategorien aufgeteilt, von denen regelmäßig vor allem zwei weitere zentrale Unterkategorien genannt werden: das Unsupervised Machine Learning (UML) und das Reinforcement Machine Learning (RML) (vgl. Black et al., 2023, S. 200; Lawson et al., 2021, S. 35 ff.).

Für ein Verständnis der Unterscheidungsmerkmale zwischen SML und den beiden weiteren zentralen Unterkategorien liefert der folgende Abschnitt eine detailliertere Systematisierung. Im Wesentlichen werden beim SML zunächst eine oder mehrere

Zielvariablen $y = (y_1, \dots, y_n)$ mit einer Menge von möglichen Eingabevariablen $x = (x_1, \dots, x_n)$ in Zusammenhang gesetzt. Anschließend wird ein Modell (F_{SML}) so angepasst, dass der Fehler zwischen den Eingabe- und Zielwerten möglichst minimiert wird: $F_{SML}: x \rightarrow y$ (vgl. Abb. 1).

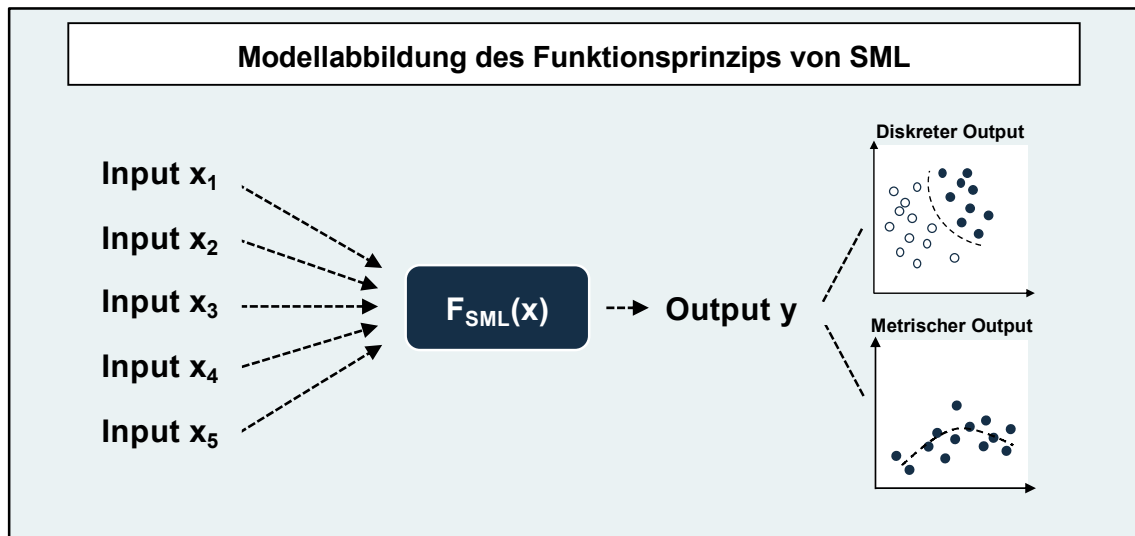


Abb. 1 Modellabbildung des Funktionsprinzips von SML
(In Anlehnung an: Lanquillon, 2019, S. 90; Lawson et al., 2021, S. 36)

Dabei kann mithilfe des SML zum einen die Modellierung für einen **metrischen** Zielwert durchgeführt werden (vgl. Goodfellow et al., 2016, S. 137 ff.; Hastie et al., 2009, S. 9 ff.). Ein Beispiel dafür aus dem Marketing ist die SML-Modellierung des Absatzvolumens – wie Pessanha; Soares (2021, S. 241 ff.) bei Drogerieartikeln zeigen. Deren Nachfrage stellen die Autoren in Abhängigkeit von Social-Media-Aktivitäten dar, darunter die Anzahl von Instagram-Likes der Produktmarke und werbender Influencer (vgl. Pessanha; Soares, 2021, S. 241 ff.). Auch Huber und Stuckenschmidt (2021, S. 1 ff.) prognostizieren einen metrischen Zielwert am Beispiel der stündlichen Nachfrage im Lebensmittelhandel und nutzen dafür 18 verschiedene Einflussfaktoren, wie Werbeaktionen, Kalenderinformationen und Wetterdaten. Neben einem metrischen Zielwert kann das SML auch für die Klassifizierung zwischen Gruppen genutzt werden, was dann einen **diskreten** Zielwert darstellt. Ein Beispiel hierfür ist die Identifikation von abwanderungswilligen Kunden („Kunde bleibt“ oder „Kunde wandert ab“). Dies zeigen u.a. Kozak et al. (2021, S. 1 ff.) mithilfe von Kundenkontoinformationen und einem SML-Entscheidungsbaumalgorithmus und analysieren damit den bestehenden Kundenstamm. Auch Esmeli et al. (2021, S. 697 ff.) verwenden SML zur Klassifikation, um bereits während eines Website-Besuchs anhand des Nutzungsverhaltens (z.B. Anzahl und Länge angesehenen Produkte, Verweildauer) vorherzusagen, ob ein Besucher ein potenzieller Käufer ist oder nicht, und so passende Marketingmaßnahmen einzuleiten.

In Bezug auf die weiteren Unterkategorien des Machine Learning kann das SML vom UML unterschieden werden. Im Gegensatz zum SML ist dort kein Fehler auf Basis der Differenz zu einer Zielvariable ($y = (y_1, \dots, y_n)$) bestimmbar, da dort keine Zielvariable

definiert ist. Folglich ist eine „Superversion“ des Lernprozesses nicht möglich. Stattdessen konzentriert sich das UML auf die Identifizierung von neuen Strukturen und Mustern innerhalb der Eingabevariablen $x = (x_1, \dots, x_n)$. Das Ziel ist die Generierung eines neuen Modells (F_{UML}), das die Eingabedaten in eine aufbereitete Darstellung der Daten transformiert. Hierbei repräsentiert die Funktion ($F_{UML}(x)$) die dadurch identifizierten Muster (vgl. Goodfellow et al., 2016, S. 142 ff.; Hastie et al., 2009, S. 485 ff.). Kharfan et al. (2021, S. 167 ff.) geben ein Beispiel für den Einsatz von UML, das zusammen mit SML dabei unterstützt, die Nachfrage nach neu eingeführten und noch nicht verkauften Modeprodukten zu prognostizieren. Mithilfe der UML werden zunächst bestehende Produkte anhand von Merkmalen in ähnliche Cluster strukturiert, wie die zum empfohlenen Verkaufspreis, Produkteigenschaften oder Monat der Markteinführung. Die neuen Produkte werden dann anhand ihrer individuellen Merkmale mittels einer SML-Klassifikation in diese Cluster eingeordnet und dann die potenzielle Nachfrage vorhergesagt.

Auch unterscheidet sich das SML wesentlich vom RML, bei dem ein durch einen Agenten repräsentiertes Modell über die Interaktion mit einer Umgebung und anhand der Prinzipien Belohnung und Bestrafung trainiert wird. Im Blickpunkt stehen hier die Umgebungszustände $S_t \in S$ (S als die Menge aller möglichen Zustände) und die Aktionen eines Agenten $A_t \in A(S_t)$ ($A(S_t)$ als die Menge aller möglichen Aktionen), die in einer Abfolge von $t=0,1,2,\dots$ agieren. Der Lernprozess verfolgt dabei die Intention, einen bestimmten Zielzustand zu erreichen, wobei die Belohnung $R_t \in R$ durch den Agenten entsprechend zu maximieren ist. Im Gegensatz zum SML wird beim RML die Abweichung vom Zielzustand nicht zwingend unmittelbar bestimmt, weshalb die Belohnung hier auch erst nach mehreren Schritten erfolgen kann (vgl. Sutton; Barto, 2018, S. ff.). Im praktischen Anwendungskontext des Marketing wird das RML besonders über sog. genetische Algorithmen eingesetzt, um u.a. Empfehlungssysteme zu gestalten und so iterativ verschiedene Produktkategorien zu fördern (vgl. Duarte et al., 2022, S. 93278).

Außerdem zählen zum erweiterten Kreis möglicher Unterkategorien des ML etwa das von Zhang (2020, S. 223) beschriebene Semi-Supervised Machine Learning (SSML) und das Transfer Machine Learning (TML). Beim TML werden Modelle, die in einem anderen Kontext trainiert werden, auf neue Probleme angewendet. Beim SSML ist – vergleichbar zum SML – eine Zielgröße vorhanden, wobei allerdings aus Zeit- und Kostengründen nur ein kleiner Teil als solche deklariert sind. Noch nicht deklarierte Datenpunkte werden dann anhand ähnlicher Merkmale automatisch zugeordnet (vgl. Zhang, 2020, S. 223 ff.). So ist für Li et al. (2016, S. 3130 ff.) die alleinige Verwendung deklarerter Verhaltensdaten nicht ausreichend, um mittels SML eine präzise Abbruchvorhersage von Online-Kursen durchzuführen. Daher ergänzen sie auch undeklarierte Daten, um eine deutlich größere Datenbasis zu erzielen und auf Basis des SSML genauere Prognosen zu erzeugen.

4. Interdisziplinäre Anwendung von SML im Marketing

Für den Forschungsbereich im Marketing wird der Wert von SML in unterschiedlichen wissenschaftlichen Untersuchungen erörtert. So stellen Huang; Rust (2021, S. 33) beispielsweise Folgendes fest: „Supervised machine learning [SML] can be used for a mature market where the market structure is stable and known to marketers, whereas unsupervised machine learning can be used for a new market or spotting outside options where the market structure and trends are unstable and unknown to marketers“. Dabei betonen die Autoren insbesondere den Stellenwert von SML für personalisierte, am Nachfrager ausgerichtete Marketingstrategien. Nach Aussage der Forschenden könne SML dabei auch die Analyse von subtilen, nicht stark ausgeprägten Reaktionen von Nachfragern erlauben (vgl. Huang; Rust, 2021, S. 35). Von den Autoren Anand; Mishra (2022, S. 339) wird dabei das SML in Anbetracht der Komplexität des Nachfragerverhaltens, das von ihnen als hochgradig nichtparametrisch, nichtlinear und zeitlich variabel beschrieben wird, als geeigneter Ansatz vorgestellt, um diesem Umstand Rechnung zu tragen.

Obgleich der Mehrwert von SML für nachfragerbezogene Analysen ein breites Echo in wissenschaftlichen Publikationen findet (vgl. auch Abbas et al., 2020, S. 304 ff.; Saini, 2021, S. 101 ff.; Geiler et al., 2022, S. 217 ff.), verlangt der Themenkomplex für die praktische Anwendung eine **differenziertere Auseinandersetzung**. Denn der beschriebene Mehrwert solcher Methoden wird im Unternehmenseinsatz bei Weitem nicht in Gänze realisiert. „Despite the significant potential of Big Data in transforming marketing activities, more than half of [...] projects are unable to achieve their goals“ stellen Erevelles et al. (2016, S. 902) mit Blick auf Mithas et al. (2013, S. 18 ff.) fest. Ein möglicher Grund für diese Diskrepanz liegt in den anspruchsvollen Voraussetzungen für eine erfolgreiche Umsetzung von SML im interdisziplinären Spannungsfeld. Infolgedessen ist eine zielgerichtete Betrachtung beider Anforderungsperspektiven erforderlich: der technischen Gesichtspunkte, die sich aus dem SML ergeben (4.1) und der anwendungsbezogenen Belange, welche die konkrete Implementierung im Marketingkontext hervorbringt (4.2).

4.1 Methodische Anforderungen des SML

Bei einer Analyse der Anforderungen aus dem **Blickwinkel des SML** wird deutlich, dass dessen Anwendungsprozess durch spezifische Herangehensweisen gekennzeichnet ist. Dementsprechend benötigen fortgeschrittene SML-Methoden etwa einen **speziellen Vorgehensprozess**, der eine Aufteilung der Gesamtdaten vorsieht und bei dem das Modell zunächst nur anhand eines zuvor separierten Datenteils, sog. Trainingsdaten (z.B. 80 Prozent des Gesamtdatensatzes), erzeugt wird. Infolgedessen erfolgt dann die Validierung der optimalen Zusammensetzung übergeordneter Feineinstellungen des Modells, die Hyperparameter, an einem weiteren Teil der Daten (z.B. 10 Prozent des Gesamtdatensatzes). Die Genauigkeit des finalen Modells wird abschließend am noch verbleibenden Teil des Datensatzes (z.B. 10 Prozent des Gesamtdatensatzes) getestet. In diesem letzten Schritt werden die Werte der Eingabevariablen $x = (x_1, \dots, x_n)$ in das erzeugte SML-Modell ($F_{SML}: x \rightarrow y$) eingesetzt und

allein auf dieser Basis die entsprechenden Werte der Zielvariable generiert (\hat{y}), die anschließend den tatsächlichen Werten (y) gegenübergestellt werden können (vgl. Berk, 2020, S. 44f.; Ramasubramanian; Singh, 2019, S. 253 ff.; Weber, 2020, S. 37 ff.).

Der Grund für dieses Vorgehen besteht darin, dass in einigen Fällen sehr elaborierte SML-Modelle dazu tendieren, eine zu komplexe Modellierung aufzuweisen und damit zu einer Überanpassung („**Overfitting**“) an die Grundlagendaten neigen. Dies kann dann anschließend deren Anwendbarkeit auf neue, unvorhergesehene Nachfrageinformationen und Ereignisse beeinträchtigen. Denn bei einem überangepassten Modell stehen sehr gute Vorhersagen bei den Trainingsdaten (In-Sample-Qualität) eher schlechteren Vorhersagen bei den Testdaten (Out-of-Sample-Qualität) gegenüber, was die Verallgemeinerbarkeit der Modellergebnisse auch für unvorhergesehene Ereignisse beeinträchtigen kann (vgl. Goodfellow et al., 2016, S. 108 ff.; Sanchez-Franco et al., 2018, S. 493; Verbeke et al., 2011, S. 2355 ff.). Als Beispiel aus der Marketingpraxis liegt eine Überanpassung bei einem Produktempfehlungssystem dann vor, wenn einzelne Nachfrager ungewöhnliche Folgekäufe tätigen – etwa aufgrund individueller Lebensumstände –, das SML-Modell diese Einzelfälle jedoch stark gewichtet und dadurch zukünftig Produktempfehlungen abgibt, die für die meisten Nachfrager nicht relevant sind. Abbildung 2 stellt das Konzept des Overfitting im Unterschied zu einem angemessenen Fit dar und zeigt dessen Tragweite für die Gültigkeit eines SML-Modells.

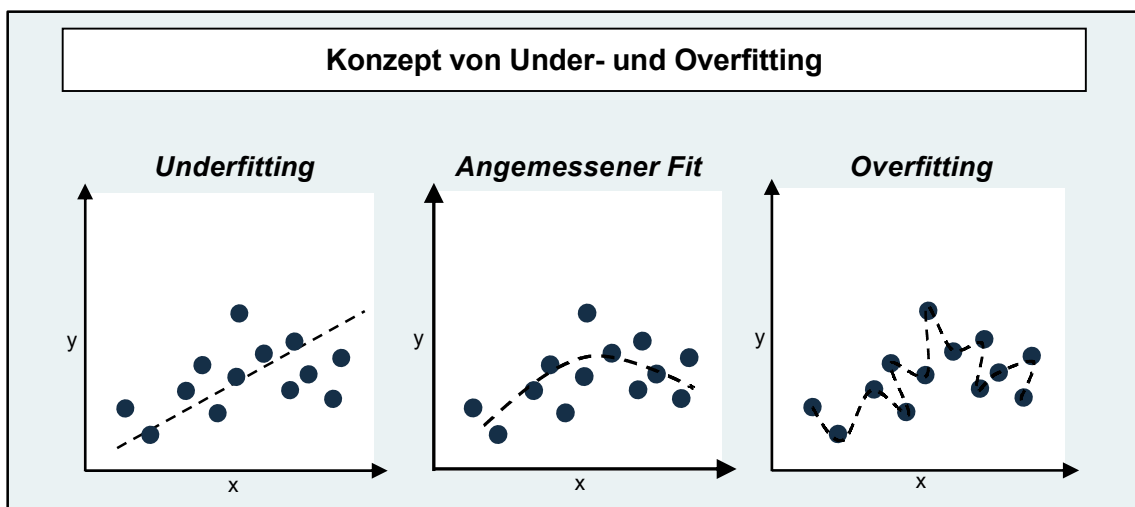


Abb. 2 Konzept von Under- und Overfitting
(in Anlehnung an: Goodfellow et al., 2016, S. 111)

Somit hebt sich dieses Vorgehen wiederum in wesentlichen Aspekten von dem Vorgehen bei einigen ökonomischen Modellen ab – und damit von einer klassischen Modellevaluation im Marketingmanagement – bei denen Kenngrößen, wie das Bestimmtheitsmaß innerhalb der Modelldatenbasis (R^2), verwendet werden (vgl. Backhaus et al., 2023, S. 88 ff.; Homburg, 2020, S. 367 f.). Dieses Vorgehen erweist sich bei einfacheren Methoden als zweckmäßig, da **traditionelle Funktionstypen** mit wenigen Parametern i.d.R. zu einer Unteranpassung („Underfitting“) neigen können (Lawson et al., 2021, S. 36). Typischerweise tritt ein Underfitting etwa dann

auf, wenn für komplexe Entscheidungen nur eine geringe Anzahl an Daten oder Variablen verwendet werden und daraufhin dann suboptimale Ergebnisse entstehen. Werden z.B. dynamische Preisstrategien nur auf Basis der vergangenen Nachfrage abgeleitet, bleiben andere dynamische Marktfaktoren unberücksichtigt. Dies kann wiederum eine unerwünschte Reduzierung der Nachfrage oder eine suboptimale Ausnutzung der Zahlungsbereitschaft zur Folge haben. Ebenso liegt eine Unteranpassung vor, wenn einzelne Marketingstimuli, wie Rabatte oder Coupons, nur auf Basis einer zu simplen Logik ermittelt werden. In diesem Fall würden wichtige Nachfrageeigenschaften unberücksichtigt bleiben mit dem Resultat, dass viele eher unrelevante Marketingmaßnahmen ergriffen werden, was zu einer ineffektiven Budgetausnutzung führt.

Das dabei zugrundeliegende Problem – das wiederum den Einsatz fortgeschrittener SML-Methoden ebnet und als Gegenstück des zuvor erläuterten Phänomens des Overfitting fungiert – ist in Abb. 3 an einem schematischen Beispiel dargestellt. Dort wird exemplarisch eine lineare Funktion zwischen zwei Eingangsvariablen (x_1, x_2) und einer Zielvariablen (y) modelliert, wie sie etwa durch eine multiple lineare Regression gebildet werden kann. Auf diese Weise lassen sich zwar gewisse Tendenzen in Marketingsachverhalten abbilden (vgl. dunkelblaue Fläche), jedoch kann dieses Modell nur eingeschränkt die Vielzahl der komplexen Datenzusammenhänge (vgl. abweichende schwarze Punkte) antizipieren (vgl. Berk, 2020, S. 13 ff.). Aus der technischen Perspektive des SML nimmt daher die Auseinandersetzung mit der kontinuierlichen Weiterentwicklung von fortgeschrittenen Algorithmen einen relevanten Stellenwert ein.

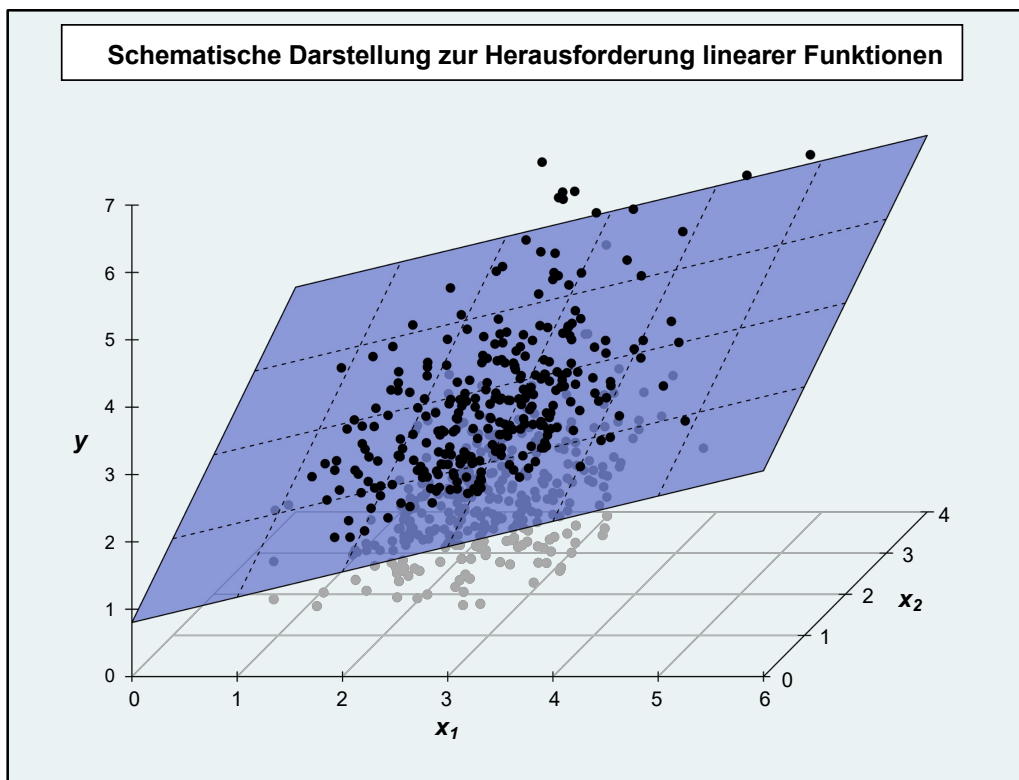


Abb. 3 Schematische Darstellung zur Herausforderung linearer Funktionen (in Anlehnung an: Berk, 2020, S. 15)

Auf dieser Grundlage existieren mittlerweile etabliertere SML-Verfahren, wie z.B. Support Vector Machines (SVM), die nicht mehr an eine bestimmte funktionale Abhängigkeit gebunden sind und dadurch auch wesentlich anspruchsvollere Abhängigkeiten erfassen können (vgl. Anand; Mishra, 2022, S. 335 ff.; Bani-Hani; Khasawneh, 2019, S. 277; Geiler et al., 2022, S. 224). SVM werden beispielsweise von Chen; Fan (2013, S. 123 ff.) effektiv im Marketingkontext eingesetzt, um den Customer Lifetime Value vorherzusagen. Auf Basis von Informationen über die Aktualität (Recency), Häufigkeit (Frequency) und dem monetären Wert (Monetary) der Nachfragerbeziehung werde so Werbeaktivitäten gezielt an den vorhergesagten künftigen Kundenwert angepasst. Über solche etablierteren SML-Verfahren hinaus werden auf der Grundlage aktueller Forschungserkenntnisse häufig **moderne Lernalgorithmen** eingeführt. Dazu gehören derzeit hochrelevante Entwicklungen bei spezifischen Architekturen des zentralen SML-Modells der Neuronalen Netze. Dies umfasst etwa die innovativen Recurrent Neural Networks mit den dazugehörigen Versionen Gated Recurrent Unit und Long-Short Term Memory (vgl. Chou et al., 2022, S. 635 ff.). Diese ermöglichen u.a. die Speicherung von Informationen in temporärer Abhängigkeit und können dadurch eine hohe Leistungsfähigkeit aufweisen, etwa bei der Modellierung der Nachfrage im Zeitverlauf (vgl. Kamara et al., 2022, S. 1 ff.; Pessanha; Soares, 2021, S. 241 ff.; Punia; Shankar, 2022, S. 1 ff.). Darüber hinaus sind Ensemble-Lerntechniken, wie Bagging und Boosting zu nennen, bei denen mehrere Modelle zu einem übergreifenden Metaalgorithmus zusammengeführt werden (vgl. Geiler et al., 2022, S. 225; Martinez et al., 2020, S. 588 ff.). Diese Ansätze ermöglichen die Integration verschiedener SML-Algorithmen und können so die Robustheit des Modells erhöhen, indem sie die Stärken verschiedener Modelle miteinander verbinden oder die Auswirkungen suboptimaler Einzelmodelle abmildern (vgl. Kharfan et al., 2021, S. 167 ff.). Relevante Beispiele hierfür aus dem Kontext des SML-Marketings sind Gradient Boosting Algorithmen, die jüngst etwa zur Vorhersage von wechselwilligen Nachfragern eingesetzt werden (vgl. Geiler et al., 2022, S. 217 ff.).

4.2 Fachspezifische Anforderungen des Marketing

Im Marketing geht wiederum ein entscheidender erster Schritt über die reine Begutachtung solcher SML-Algorithmen hinaus – ein Fokus, der dagegen in technisch orientierten Publikationen oftmals als Schwerpunkt zu beobachten ist (vgl. hier exemplarisch: Ahmed et al., 2022, S. 573 ff.; Pessanha; Soares, 2021, S. 241 ff.; Wang et al., 2019, S. 262 ff.; Westland et al., 2019, S. 1592 ff.). Denn während dort der Einsatz von SML aufgrund der themenspezifischen Schwerpunktlegung regelmäßig bereits vorausgesetzt wird, erfordert die **Marketing-Sicht** zunächst eine initiale Bewertung darüber, inwieweit die Voraussetzungen den Einsatz nicht nur begünstigen, sondern auch effektiv zulassen. Im Ergebnis lässt sich demzufolge ableiten, dass der Prozess in diesem interdisziplinären Rahmen vielmehr eine Prüfung der originären Eignung von SML im Hinblick auf die Marketingaufgaben und die bestehenden Rahmenbedingungen erforderlich macht. Wesentliche Kriterien dafür lassen sich aus der wissenschaftlichen Literatur wie folgt extrahieren:

(1) Im Gegensatz zu klassischen Verfahren der induktiven Statistik, lassen sich anspruchsvolle SML-Verfahren i.d.R. nicht mehr mit einfachen Tabellenkalkulationspro-

grammen umsetzen (vgl. Mittag; Schüller, 2020, S. 384 f.). Denn sowohl das Datenvolumen, beispielsweise bei sekundengenauen Verhaltensdaten, als auch die Implementierung fortgeschrittener Algorithmen (z.B. Neuronale Netze, SVMs, Random Forests) sind damit nicht durchführbar. So erfordern SML-Methoden i.Allg. Kompetenzen in einschlägigen Programmiersprachen (u.a. R, Python), Programmbibliotheken mit entsprechenden Algorithmen (u.a. für Neuronale Netze „PyTorch“ oder „TensorFlow“) sowie geeignete Entwicklungsumgebungen (u.a. Cloud-Computing-Umgebungen wie „Microsoft Azure“) (vgl. Fraunhofer-Gesellschaft, 2018, S. 167 f.; Lawson et al., 2021, S. 41 f.). Insgesamt werden für den SML-Einsatz somit klare infrastrukturelle Rahmenbedingungen benötigt, z.B. im Hinblick auf solche technischen Gegebenheiten.

(2) Darüber hinaus ist eine Bewertung des Marketingproblems vor dem Hintergrund seiner inhärenten Struktur notwendig. Hierbei handelt es sich konkret um die Bewertung, inwiefern komplexe, **nicht-lineare Beziehungen** innerhalb der Marketingdaten zu erwarten oder tatsächlich vorhanden sind. Dies begünstigt dann tendenziell die Vorteilhaftigkeit des Einsatzes von fortgeschrittenen SML-Algorithmen gegenüber einfacheren statistischen Methoden (vgl. Birim et al., 2021, S. 5; Nufer; Muth, 2023, S. 40 ff.).

(3) Ebenfalls kann für einen effektiven SML-Einsatz generell ein hoher Umfang von Marketingdaten als Kriterium identifiziert werden. Dahingehend heben Black et al. (2023, S. 203) hervor, dass im SML-Kontext zur Modellierung „upwards of 200 events per candidate predictor may be required [...] compared with 20 events per candidate predictor using a statistical model.“ Wie Chou et al. (2022, S. 635 ff.) bei der Prädiktion des Wiederkaufs von Nachfragern feststellen, kann SML die Vorhersagegenauigkeit des Modells insbesondere bei umfangreichen Datensätzen deutlich erhöhen und ist folglich gerade für solche Anwendungsfälle prädestiniert. Einhergehend mit dieser Anforderung nach ausdrücklich **hochdimensionalen Daten** ergibt sich folgerichtig eine Problematik, wenn sehr anspruchsvolle SML-Modelle auf Datensätze mit einer geringen Dimensionalität und Komplexität angewendet werden (vgl. Berk, 2020, S. 58 f.; Lawson et al., 2021, S. 37).

Hinsichtlich des darauffolgenden Prozesses eines Einsatzes von SML-Anwendungen im Marketing zeigt sich, dass die Evaluation der Lernalgorithmen in technisch orientierten SML-Publikationen regelmäßig auf der Basis der Modellgüte in den Daten erfolgt. Hierbei wird üblicherweise der durchschnittliche Modellierungsfehler zwischen dem vom Modell generierten Wert der Zielvariable (\hat{y}) und dem tatsächlichen Wert (y) berechnet. Dies erfolgt etwa in Form des Mean Absolute Error ($\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)$), wobei dieser mitunter auch quadriert wird, damit sich positive und negative Abweichungen nicht ausgleichen (vgl. Bogaert et al., 2021, S. 9). Über diese Bewertung hinaus erhalten im fachübergreifenden Kontext besonders die praktischen Implikationen großes Interesse. Diese sollten sich aus der Modellierung ableiten lassen und so eine verlässliche Grundlage für Marketingentscheidungsträger bieten (vgl. Oztekin et al., 2016, S. 699). Dementsprechend betonen Forschende im vorliegenden Marketingkontext die Bedeutung der Interpretierbarkeit der Wirkung einzelner Einflussvariablen und deren Kompatibilität mit bestehendem Marketingwissen. Als ein zentraler Punkt der aktuellen wissenschaftlichen Diskussion kristallisiert sich daher hier der übergreifende Bereich der **Modelltransparenz** heraus. So resümieren die Autoren Chou et al. (2022, S. 645): „the recent research trend [...] seeks for higher interpretability of machine learning models“.

In der praktischen Umsetzung im Marketing kann diese Transparenz einerseits etwa durch die Wahl des SML-Algorithmus begünstigt werden. Ein Beispiel dafür ist die Nutzung des Modells „Least Absolute Shrinkage and Selection Operator“ (LASSO), das den Einfluss irrelevanter Prädiktoren reduziert und so die Schlüsselvariablen transparent werden lässt (vgl. hierzu ausführlich: Rezaei et al., 2021, S. 233 ff.). Chou et al. (2022, S. 643) zeigen dessen Einsatz für die Prognose von Wiederkäufen und kommen zu dem folgenden Schluss: „Lasso regression tends to shrink effect sizes of non-crucial variables and in our case, despite having ~70 to ~100 features ... most predictors turn out to have zero or close to zero coefficients.“ Aus einer großen Anzahl von Transaktionsdetails bleiben so nur fünf zentrale Faktoren für die Vorhersage von Wiederkäufen übrig (u.a. Nachfragehäufigkeit, Zeitintervall zum ersten Kauf und Zahlungsmethode), was die Transparenz der Modellierung deutlich erhöht. Andererseits existieren selbst bei komplexeren SML-Modellen Ansätze, die ein Verständnis für die Bedeutung einzelner Variablen im Modell selbst vermitteln. Eine Möglichkeit dafür bietet die Sensitivitätsanalyse, wobei durch Entfernen und Wiedereinführen von Variablen deren Auswirkung auf die Vorhersagegenauigkeit gemessen wird. Dies zeigen etwa Bogaert et al. (2021, S. 1 ff.) anhand ihrer SML-basierten Prognose für die Nachfrage nach Hollywoodfilmen. Die Forschenden analysieren mittels einer Sensitivitätsanalyse den Beitrag der Inputvariablen – darunter Film-, Facebook- und Twitterdaten –, indem sie diese zunächst einzeln aus dem Modell entfernen und dann wieder hinzufügen. In der Zwischenzeit erfolgt die Bestimmung der Prognosegüte – mit und ohne die einzelnen Inputvariablen. Durch dieses Vorgehen können dann innerhalb des SML-Modells wichtige Inputvariablen für die Nachfrage identifiziert werden, wie in diesem Fall die Gesamtzahl der Kommentare, die Anzahl negativer Kommentare sowie die Laufzeit der Filme. Eine andere Möglichkeit besteht darin, das SML-Modell nicht anhand von dessen Prognose, sondern von dessen Struktur zu analysieren. So können etwa die in einem Modell hergestellten Verbindungen ausgewertet werden, um den Einfluss der Input-Variablen auf den Output zu quantifizieren, wobei der weitverbreitete SML-Algorithmus der Neuronalen Netze relevante Möglichkeiten eröffnet. So zielt etwa das Forschungsbeispiel von Nufer; Muth (2022, S. 55 ff.) darauf ab, die Auswirkungen verschiedener Markenassoziationen auf die Gesamtwahrnehmung einer Marke mit SML zu modellieren und dabei prägende Faktoren des Markenimages transparent nachzuvollziehen. Dafür werden mithilfe eines Neuronalen Netzes neun zentrale Markenassoziationen als Eingabevariablen $x = (x_1, x_2, \dots, x_9)$ mit der Gesamtwahrnehmung einer bekannten Bekleidungsmarke (y) in Zusammenhang gesetzt. Das in Abb. 4 (links) dargestellte Neuronale Netz wird dafür mit einem zuvor separierten Datenteil erstellt und mit einem weiteren Datenteil erfolgt die Optimierung von bestimmten Hyperparametern, in diesem Fall also Netzstrukturen wie die Anzahl der Neuronenschichten. Die Genauigkeit des Modells wird schließlich am noch verbleibenden Teil des Datensatzes getestet, wobei im Zuge dessen die Gesamtbewertung der Marke durch die Nachfrager auf der Grundlage der Markenassoziationen prädiziert wird. Um die Transparenz des dabei erstellten Neuronalen Netzes deutlich zu erhöhen, werden die Netzwerkverbindungen in der Studie – neben der Darstellung des generierten Netzmodells – ausgewertet (Abb. 4, rechts). Damit lassen sich daraufhin wichtige Aspekte des Markenimages analysieren. Diese Erkenntnisse eröffnen dann relevante Implikationen für **praktische Marketingentscheidungen** der analysierten Marke hinsichtlich Preisgestaltung, Markenführung und Kommunikation (vgl. hierzu ausführlich: Nufer; Muth, 2022, S. 55 ff.).




Abb. 4 Transparenz von SML im Marketing am Beispiel Neuronaler Netze
(In Anlehnung an: Nufer; Muth, 2022, S. 59 f.)

5. Limitationen von SML bei der nachfragerbezogenen Datenmodellierung im Marketing

Trotz oder gerade wegen des großen Potenzials von SML-Modellen ist gleichermaßen der Notwendigkeit nachzukommen, auch die **Grenzen** solcher Modelle ausdrücklich aufzuzeigen, um so deren Fähigkeiten klar definieren zu können. Dies ist ebenfalls für den praktischen Einsatz im Marketing von zentralem Stellenwert. Denn besonders der Einsatz von SML für nachfragerbezogene Analysen weist vielfältige Anforderungen und Einschränkungen auf. Insgesamt ist dabei die Güte der SML-Modelle besonders durch die Beschaffenheit der zugrundeliegenden Daten determiniert: „If data input is erroneous or biased, output is likely to be biased too“ (Huang; Rust, 2021, S. 46). Daher rückt die **Datengrundlage** in den Fokus der Limitationen. Denn hier bedürfen gleich mehrere Gesichtspunkte einer besonderen Beachtung im speziellen Marketingkontext:

(1) Zunächst ist zu berücksichtigen, dass, entsprechend der „No-free-Lunch“-Theoreme (vgl. Goodfellow et al., 2016, S. 115; Wolpert, 1996, S. 1341 ff.), **kein universell überlegenes Verfahren** des SML existiert, das generell für alle Anwendungsprobleme die höchste Eignung besitzt. Auch wenn mittlerweile Möglichkeiten bestehen, SML-Aufgaben automatisch und mit einem geringen oder gar keinem manuellen Eingriff zu erledigen, wird i.d.R. auch bei diesem Ansatz – der unter dem Begriff „AutoML“ subsumiert ist – zwischen mehreren Modelloptionen mit dem niedrigsten Prognosefehler ausgewählt (vgl. Alsharif et al., 2022, S. 5297 ff.). Grundsätzlich ist somit, trotz mitunter vielfach erfolgreicher Implementierung gewisser SML-

Algorithmen, deren Ergebnisqualität maßgeblich abhängig von den zugrundeliegenden Daten (vgl. Lanquillon, 2019, S. 137), was die Wichtigkeit der problemindividuellen Fallabwägung für die Marketingpraxis unterstreicht.

(2) Der spezifische Anwendungskontext der Nachfragerperspektive verschärft die Herausforderungen rund um die Datengrundlage zusätzlich. So können SML-Resultate auf der Grundlage potenziell voreingenommener Daten trotz der neutralen algorithmischen Datenverarbeitung gewisse **Ergebnisungleichgewichte** aufweisen (vgl. Lambrecht; Tucker, 2019, S. 2966 ff.; Huang; Rust, 2021, S. 46). Ein Beispiel ist die Vorhersage einer potenziellen Kundenabwanderung, wenn die Zahl der verbleibenden Kunden die der abwandernden deutlich übersteigt. Wenn dann die meisten Trainingsdaten von Nachfragern stammen, die dem Unternehmen treu bleiben – was der Regelfall darstellt –, hat das SML-Modell Schwierigkeiten, die Muster von potenziell abwandernden Nachfragern richtig zu erkennen und sie so mit effektiven Marketingmaßnahmen anzusprechen (vgl. hierzu exemplarisch: Verbeke et al., 2011, S. 2359). Im noch breiteren Kontext zeigt sich, dass insbesondere marginalisierte Gruppen anfällig für solche Verzerrungen im Modell sein können (vgl. Black et al., 2023, S. 203). Eine unausgewogene Merkmalsverteilung, wie Geschlecht, Alter oder ethnische Zugehörigkeit, kann dann zu sehr problematischen Modellverzerrungen führen. Ein Beispiel aus der Marketingpraxis hierfür ist, wenn eine Werbekampagne individuell auf Basis einer Kundenkarte ausgespielt wird, die historischen Daten aber überwiegend Männer enthalten. Aufgrund dieses Ungleichgewichts besteht bei der Nutzung von SML die Gefahr, dass andere Geschlechter in der Vorhersage und damit auch in der Ausspielung von potenziellen Werbemaßnahmen weniger treffsicher persönlich erfasst werden. Um derartige Verzerrungen abzuschwächen, können Maßnahmen wie Oversampling eingesetzt werden. Hier werden Beobachtungen von Minderheiten dupliziert und dem Datensatz für die Modellentwicklung absichtlich hinzugefügt (vgl. Verbeke et al., 2011, S. 2359). In der Konsequenz erfordert der Einsatz von SML jedoch eine sehr gezielte, systematische Überprüfung des Datenbestandes auf ein solches nachfragerbezogenes Ungleichgewicht.

(3) Darüber hinaus ist zu bedenken, dass SML-Methoden im Allgemeinen mit **historischen** Daten trainiert werden. Allerdings reflektieren die dem SML zugrundeliegenden Daten implizit zurückliegende Entscheidungen. Sie können somit auch die vergangene strategische Ausrichtung sowie die damalige Unternehmens- und Marktsituation widerspiegeln. Die dadurch gesetzten Rahmenbedingungen sind gegenwärtig und zukünftig nicht zwingend identisch. So spiegeln sich der Rahmen von Situationen und deren Sentiment oft nicht vollständig in den Daten und folglich auch nicht im darauf aufbauenden Modell wider (vgl. Huang; Rust, 2021, S. 46). Eine zentrale Anforderung an Marketingentscheidungsträger liegt somit in der kritischen Bewertung der Erkenntnisse aus dem SML – insbesondere im Hinterfragen des Kontextes der Datengrundlage und deren Einordnung in einen ganzheitlichen Zusammenhang (vgl. hierzu ausführlich: Welge et al., 2017, S. 419 ff.).

6. Fazit

Das dynamisch wachsende Feld des SML hält als **integraler Bestandteil** aktuell sehr umfassend Einzug in die Marketingpraxis und wird regelmäßig als sehr bedeutend für betriebswirtschaftliche Anwendungsprobleme eingestuft (vgl. u.a. Homburg, 2020, S. 454). Denn mit den damit verbundenen Modellen können umfassende Erklärungsmuster und Vorhersagen über Marketingprozesse erfolgen, deren hohe Komplexität keine rein manuelle Verarbeitung zulässt (vgl. Birim et al., 2022, S. 3).

Der vorliegende konzeptionelle Forschungsbeitrag kann für diesen interdisziplinären Anwendungszweck eine Reihe zu berücksichtigender Kernaspekte herleiten. Was die **praktische Implementierung** im Marketing betrifft, so zeigen sich aus technischer SML-Sicht spezielle Anforderungen, wozu u.a. die Gewährleistung etablierter Vorgehensweisen zur Sicherung der Modellqualität (Datenaufteilung, Hyperparameteranpassung, Out-of-Sample Testung) sowie die Berücksichtigung neuerer Entwicklungen in der Architektur von Lernalgorithmen gehören. Hier werden SML Ensembles als Metaalgorithmus und moderne Architekturen Neuronaler Netze zur Modellierung komplexer Abhängigkeitsbeziehungen angeführt (vgl. u.a. Chou et al., 2022, S. 635-646; Geiler et al., 2022, S. 217 ff.; Goodfellow et al., 2016, S. 108 ff.; Lawson et al., 2021, S. 36 ff.). Aus Sicht des Marketing zeigt sich darüber hinaus, dass die Integration von SML zunächst einer initialen Notwendigkeits- und Eignungsüberprüfung bedarf. Hier wird eine Diskrepanz zwischen der informationswissenschaftlichen Literatur und den Anforderungen der Marketingpraxis deutlich. Als relevante Aspekte werden u.a. die Kompatibilität der technischen Rahmenbedingungen, die zu erwartende Ausprägung nicht-linearer Problemzusammenhänge sowie eine ausreichende Datenmenge und -dimensionalität herausgearbeitet (vgl. u.a. Black et al., 2023, S. 200 ff.; Fraunhofer-Gesellschaft 2018, S. 167 f.; Nufer; Muth, 2023, S.40 ff.). Auch die Bewertung der Algorithmen im Hinblick auf deren Implikationen für die Marketingpraxis wird diskutiert. Dazu werden Methoden wie die der Sensitivitätsanalyse oder der Analyse der Modellstrukturen eingesetzt, um Zusammenhänge von SML-Modellen für das Marketing transparenter zu machen (vgl. u.a. Bogaert et al., 2021, S. 1 ff.; Nufer; Muth, 2022, S. 55 ff.; Rezaei et al., 2021, S. 233 ff.). Die darauf aufbauenden Limitationen verdeutlichen auch mögliche Einschränkungen durch das sog. „Lernen aus Daten“ (Lanquillon, 2019, S. 118): Die Zuverlässigkeit der SML-Modelle weist eine maßgebliche Abhängigkeit zu der zugrundeliegenden Datenbasis auf und mögliche Ungleichgewichte – insbesondere bei nachfragerbezogenen Daten – erfordern die Kompensierung von Verzerrungen im Endmodell. Ebenso verlangt eine potenziell vergangenheitsorientierte Informationsbasis eine Einordnung in einen zukunftsgerichteten Gesamtzusammenhang (vgl. u.a. Huang; Rust, 2021, S. 30 ff.; Verbeke et al., 2011, S. 2355 ff.; Wolpert, 1996, S. 1341 ff.). Schließlich unterstreichen diese gewonnenen Erkenntnisse die Notwendigkeit einer Anpassung, einer reflektierten Anwendung und einer kritischen Bewertung von SML-Ansätzen bei der Anwendung im Marketingumfeld.

Die Bandbreite der vorliegend dargestellten Anwendungsbeispiele von SML in der Marketingdisziplin repräsentiert nur einen kleinen Teil aus einem umfangreichen Anforderungsspektrum und erfordert eine weitergehende Exploration. Infolgedessen zeigt sich die Integration von SML in die Marketingpraxis als ein anspruchsvolles und mehrdimensionales Unterfangen, das einer **fortwährenden Auseinandersetzung** im praktischen und akademischen Kontext bedarf. Ähnlich verhält es sich für die vorgestellten Ansätze des SML, wobei der Diskurs allenfalls einen selektiven Bestandteil

aus einem breit gefächerten Forschungsfeld darstellt (vgl. hierzu ausführlich: Verma et al., 2021, S. 1 ff.; Vlačić et al., 2021, S. 187 ff.). Gleichzeitig liefert der vorliegende Forschungsbeitrag einige wesentliche Erkenntnisse zu diesem interdisziplinären Integrationsprozess und beleuchtet die besonderen Rahmenbedingungen, die mit der Anwendung von SML in der Marketingpraxis verbunden sind, um damit effektive Analyseergebnisse zu generieren.

Literatur

Abbas, Z.; Merbis, R.; Motruk, A. (2020): Leveraging Machine Learning to Deepen Customer Insight, in: Applied Marketing Analytics, 5(4), pp. 304-311.

Ahmed, S.; Chakraborty, R.K.; Essam, D. L.; Ding, W. (2022): Poly-linear regression with augmented long short term memory neural network: Predicting time series data, in: Information Sciences, 606, pp. 573-600.

Alsharef, A.; Aggarwal, K.; Sonia, S.; Kumar, M.; Mishra, A. (2022): Review of ML and AutoML Solutions to Forecast Time-Series Data, in: Archives of Computational Methods in Engineering, 29(7), pp. 5297-5311.

Anand, S.; Mishra, K. (2022): Identifying potential millennial customers for financial institutions using SVM, in: Journal of Financial Services Marketing, 27, pp. 335-345.

Backhaus, K.; Erichson, B.; Gensler, S.; Weiber, R.; Weiber, T. (2023): Multivariate Analysemethoden – Eine anwendungsorientierte Einführung, 17. Aufl., Berlin, Heidelberg.

Bani-Hani, D.; Khasawneh, M. (2019): A Recursive General Regression Neural Network (R-GRNN) Oracle for classification problems, in: Expert Systems with Applications, 135, pp. 273-286.

Berk, R.A. (2020): Statistical Learning from a Regression Perspective, 3. Aufl., Cham.

Birim, S.; Kazancoglu, I.; Mangla, S.K.; Kahraman, A.; Kazancoglu, Y. (2022): The derived demand for advertising expenses and implications on sustainability: a comparative study using deep learning and traditional machine learning methods, in: Annals of Operations Research, pp. 1-31.

Black, J. E.; Kueper, J. K.; Williamson, T. S. (2022): An introduction to machine learning for classification and prediction, in: Family Practice, 40(1), pp. 200-204.

Bogaert, M.; Ballings, M.; Van den Poel, D.; Oztekin, A. (2021): Box office sales and social media: A cross-platform comparison of predictive ability and mechanisms, in: Decision Support Systems, 147, pp. 1-15.

Bundesministerium für Wirtschaft und Energie (2020): Perspektiven der künstlichen Intelligenz für den Einzelhandel in Deutschland, https://www.bmwk.de/Redaktion/DE/Publikationen/Digitale-Welt/perspektiven-kuenstliche-intelligenz-fuer-einzelhandel.pdf?__blob=publicationFile&v=1, Zugriff: 27.12.2023.

Castán-Lascorz, M.A.; Jiménez-Herrera, P.; Troncoso, A.; Asencio-Cortés, G. (2022): A new hybrid method for predicting univariate and multivariate time series based on pattern forecasting, in: Information Sciences, 586, pp. 611-627.

Chen, Z.-Y.; Fan, Z.-P. (2013): Dynamic customer lifetime value prediction using longitudinal data: An improved multiple kernel SVR approach, in: Knowledge-Based Systems, 43, pp. 123-134.

Chou, P.; Chuang, H.H.C.; Chou, Y.C.; Liang, T.P. (2022): Predictive analytics for customer repurchase: Interdisciplinary integration of buy till you die modeling and machine learning, in: European Journal of Operational Research, 296(2), pp. 635-651.

Duarte, V.; Zuniga-Jara, S.; Contreras, S. (2022): Machine Learning and Marketing: A Systematic Literature Review, in: IEEE Access, 10, pp. 93273-93288.

Erevelles, S.; Fukawa, N.; Swayne, L. (2016): Big Data consumer analytics and the transformation of marketing, in: Journal of Business Research, 69(2), pp. 897-904.

Esmeli, R.; Bader-El-Den, M.; Abdullahi, H. (2021): Towards early purchase intention prediction in online session based retailing systems, in: Electronic Markets, 31, pp. 697-715.

Fraunhofer-Gesellschaft (2018): Maschinelles Lernen – Kompetenzen, Anwendungen und Forschungsbedarf, https://www.bigdata.fraunhofer.de/content/dam/bigdata/de/documents/Publicationen/Fraunhofer_Studie_ML_201809.pdf, Zugriff: 27.12.2023.

Geiler, L.; Affeldt, S.; Nadif, M. (2022): A survey on machine learning methods for churn prediction, in: International Journal of Data Science and Analytics, 14, pp. 217-242.

Goodfellow, I.; Bengio, Y.; Courville, A. (2016): Deep Learning, Cambridge, Massachusetts: MIT Press.

Halfmann, M. (2022): Marketing Analytics – Trend oder Zukunft?, in: Halfmann, M.; Schüller, K. (Hrsg.): Marketing Analytics, Wiesbaden, S. 3-14.

Hastie, T.; Tibshirani, R.; Friedman, J. (2009): The Elements of Statistical Learning. Springer New York.

Homburg, C. (2020): Marketingmanagement: Strategie - Instrumente - Umsetzung – Unternehmensführung, 7. Aufl., Berlin.

Huang, M.-H.; Rust, R.T. (2021): A strategic framework for artificial intelligence in marketing, in: Journal of the Academy of Marketing Science, 49(1), pp. 30-50.

Huber J.; Stuckenschmidt H. (2021): Intraday shelf replenishment decision support for perishable goods, in: International Journal of Production Economics, 231, pp. 1-14.

Kamara, A.F.; Chen, E.H.; Pan, Z. (2022): An ensemble of a boosted hybrid of deep learning models and technical analysis for forecasting stock prices, in: Information Sciences, 594, pp. 1-19.

Karthik, P.V.V.; Rao, P.G.P.; Narsimlu, M. (2020): Case Study: Lead Conversion of Digital Marketing Data Using Predictive Analytics, in: Kumar, A; Paprzycki, M.; Gunjan, V. (Hrsg.): ICDSMLA 2019 – Lecture Notes in Electrical Engineering, Singapore, S. 510-519.

Khafan, M.; Chan, V.W.K.; Efendigil, T.F. (2021): A data-driven forecasting approach for newly launched seasonal products by leveraging machine-learning approaches, in: Annals of Operations Research, 303, pp. 159-174.

- Kozak, J.; Kania, K.; Juszczuk, P.; Mitrega, M. (2021): Swarm intelligence goal-oriented approach to data-driven innovation in customer churn management, in: *International Journal of Information Management*, 60, S. 1-16.
- Lambrecht, A.; Tucker, C. (2019): Algorithmic bias? An empirical study of apparent gender-based discrimination in the display of STEM career ads, in: *Management Science*, 65(7), pp. 2966-2981.
- Lanquillon, C. (2019): Grundzüge des maschinellen Lernens, in: Sacht, S.; Lanquillon, C. (Hrsg.): *Blockchain und maschinelles Lernen - Wie das maschinelle Lernen und die Distributed Ledger-Technologie voneinander profitieren*, Berlin, Heidelberg, S. 89-142.
- Lawson, C.E.; Martí, J.M.; Radivojevic, T.; Jonnalagadda, S.V.R.; Gentz, R.; Hillson, N.J.; Peisert, S.; Kim, J.; Simmons, B.A.; Petzold, C.J.; Singer, S.W.; Mukhopadhyay, A.; Tanjore, D.; Dunn, J.G.; Garcia Martin, H. (2021): Machine learning for metabolic engineering: A review, in: *Metabolic Engineering*, 63, pp. 34-60.
- Li, W.; Gao, M.; Li, H.; Xiong, Q.; Wen, J.; Wu, Z. (2016): Dropout Prediction in MOOCs Using Behavior Features and Multi-View Semi-Supervised Learning, in: *2016 International Joint Conference on Neural Networks (IJCNN)*, pp. 3130-3137.
- Luu, H. (2018): *Beginning Apache Spark 2. With Resilient Distributed Datasets, Spark SQL, Structured Streaming and Spark Machine Learning library*, Berkeley.
- Mariani, M.M.; Perez-Vega, R.; Wirtz, J. (2021): AI in marketing, consumer research and psychology: A systematic literature review and research agenda, in: *Psychology & Marketing*, 39(4), pp. 755-776.
- Martinez, A.; Schmuck, C.; Pereverzyev, S.; Pirker, C.; Haltmeier, M. (2020): A machine learning framework for customer purchase prediction in the non-contractual setting, in: *European Journal of Operational Research*, 281(3), pp. 588-596.
- Mitchell, T. (1997): *Machine Learning*, New York.
- Mithas, S.; Lee, M.R.; Earley, S.; Murugesan, S.; Djavanshir, R. (2013): Leveraging Big Data and Business Analytics, in: *IT Professional*, 15(6), pp. 18-20.
- Mittag, H. J.; Schüller, K. (2020): *Statistik. Eine Einführung mit interaktiven Elementen*, 6. Aufl., Berlin, Heidelberg.
- Mustak, M.; Salminen, J.; Plé, L.; Wirtz, J. (2021): Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda, in: *Journal of Business Research*, 124, pp. 389-404.
- Nufer, G.; Muth, M. (2022): Artificial Intelligence in Marketing Analytics: The Application of Artificial Neural Networks for Brand Image Measurement, in: *Journal of Marketing Development and Competitiveness*, 16(1), pp. 55-63.
- Nufer, G.; Muth, M. (2023): Machine Learning zur Modellbildung im Marketing, in: *WiSt - Wirtschaftswissenschaftliches Studium*, 52(6), S. 40-43.
- Oztekin, A.; Kizilaslan, R.; Freund, S.; Iseri, A. (2016): A data analytic approach to forecasting daily stock returns in an emerging market, in: *European Journal of Operational Research*, 253(3), pp. 697-710.
- Pavlyshenko, B.M. (2019): Machine-learning models for sales time series forecasting, in: *Data*, 4, pp. 1-15.

Pessanha, G.R.G.; Soares, E.A. (2021): Just One Post? Forecasts of Daily Sales of Beauty and Cosmetics Retail Companies Based on the Influence of Social Media, in: Revista Brasileira de Marketing, 20, pp. 241-267.

Proserpio, D.; Hauser, J. R.; Liu, X.; Amano, T.; Burnap, A.; Guo, T.; Lee, D.; Lewis, R.; Misra, K.; Schwarz, E.; Timoshenko, A.; Xu, L.; Yoganarasimhan, H. (2020): Soul and Machine (Learning), in: Marketing Letters, 31(4), pp. 393-404.

Punia, S.; Shankar, S. (2022): Predictive analytics for demand forecasting: A deep learning-based decision support system, in: Knowledge Based Systems, 258, pp. 1-11.

Ramasubramanian, K.; Singh, A. (2019): Machine Learning Using R. With Time Series and Industry- Based Use Cases in R, 2. Aufl., Berkeley.

Rezaei, M.; Cribben, I.; Samorani, M. (2021): A clustering-based feature selection method for automatically generated relational attributes, in: Annals of Operations Research, 303(1-2), pp. 233-263.

Sanchez-Franco, M.J.; Cepeda-Carrion, G.; Roldan, J.L. (2019): Understanding relationship quality in hospitality services A study based on text analytics and partial least squares, in: Internet Research, 29(3), pp. 478-503.

Smirnov, D.; Huchzermeier, A. (2020): Analytics for labor planning in systems with load-dependent service times, in: European Journal of Operational Research, 287, pp. 668-681.

Sutton, R.S.; Barto, A.G. (2018): Reinforcement Learning: An Introduction, 2. Aufl., Cambridge.

Verbeke, W.; Martens, D.; Mues, C.; Baesens, B. (2011): Building comprehensible customer churn prediction models with advanced rule induction techniques, in: Expert systems with applications, 38(3), pp. 2354-2364.

Verma, S.; Sharma, R.; Deb, S.; Maitra, D. (2021): Artificial intelligence in marketing: Systematic review and future research direction, in: International Journal of Information Management Data Insights, 1, pp. 1-8.

Vlačić, B.; Corbo, L.; Costa e Silva, S.; Dabić, M. (2021): The evolving role of artificial intelligence in marketing: A review and research agenda, in: Journal of Business Research, 128, pp. 187-203.

Wang, Q.F.; Xu, M.; Hussain, A. (2019): Large-scale Ensemble Model for Customer Churn Prediction in Search Ads, in: Cognitive Computing, 11(2), pp. 262-270.

Welge, M.K.; Al-Laham, A.; Eulerich, M. (2017): Strategisches Management. Grundlagen – Prozess – Implementierung, 7. Aufl., Wiesbaden.

Welsch, A.; Eitle, V.; Buxmann, P. (2018): Maschinelles Lernen, in: HMD Praxis der Wirtschaftsinformatik, Vol. 55, S. 366-382.

Westland, J.C.; Mou, J.; Yin, D.F. (2019): Demand cycles and market segmentation in bicycle sharing, in: Information Processing & Management, 56(4), pp. 1592-1604.

Wolpert, D H. (1996): The Lack of A Priori Distinctions Between Learning Algorithms, in: Neural Computation, 8(7), pp. 1341-1390.

Wu, Z.X.; Li, Z.Y. (2021): Customer churn prediction for commercial banks using customer-value-weighted machine learning models, in; Journal of Credit Risk, 17, pp. 15-42.

Zhang, X.D. (2020): A Matrix Algebra Approach to Artificial Intelligence, Singapore.

Schlüsselwörter

Datenbasierte Prognosen, Künstliche Intelligenz, Interdisziplinäre Anwendungsforschung, Marketing Analytics, Modelltransparenz, Nachfragerverhalten, Supervised Machine Learning,

KI • KÜNSTLICHE INTELLIGENZ • PRODUCT
DESIGN • AI • ARTIFICIAL INTELLIGENCE
DIGITALISIERUNG • LARGE LANGUAGE
MODELS • GENERATIVE KI • GENERATIVE
AI • BIG DATA • KI • DIGITAL MARKETING
INFLUENCER MARKETING • BOTS • VIRTUAL
INFLUENCER • ROBOTER • MARKETING
ANALYTICS • PRODUCT DESIGN • AI
GENERATIVE AI • KI • DIGITALISIERUNG
ALGORITHMUS • DIGITAL MARKETING
LARGE LANGUAGE MODELS • ARTIFICIAL
INTELLIGENCE • BOTS • ROBOTER
VIRTUAL INFLUENCER • AI • MARKETING
ANALYTICS • KÜNSTLICHE INTELLIGENZ
EMPFEHLUNGsalgorithmus • BIG DATA

AfM

Arbeitsgemeinschaft
für Marketing