

Sunday gleich Funday? Die Analyse und Prognose von Zeiteffekten im Online-Kundenverhalten im Versicherungsbereich mittels Machine Learning

Lukas Wolf, Elisabeth Galehr-Fritsch und Martina Steul-Fischer

Zusammenfassung

Kunden verhalten sich unterschiedlich abhängig von der Tageszeit, dem Wochentag oder der Jahreszeit. Allerdings wurde der Einfluss dieser zeitlichen Faktoren auf das Kundenverhalten bisher kaum erforscht. In dieser Studie wird untersucht, inwiefern Zeiteffekte im Online-Verhalten von Versicherungskunden (Klickverhalten, Versicherungskäufe, Gerätewahl) bestehen und ob Zeitreihenmodelle auf Basis dieser Zeiteffekte spezifisches Kundenverhalten vorhersagen können. Die Studie nutzt einen umfassenden Clickstream-Datensatz eines deutschen Versicherers, der detaillierte Mausklicks aller Webseitenbesucher über einen Zeitraum von zwei Jahren beinhaltet. Dabei zeigt sich, dass am Wochenende und an Feiertagen signifikant weniger Kunden die Webseite besuchen oder eine Versicherung abschließen. Der Einfluss des Wochentags ist stärker, wenn stationäre Geräte genutzt werden als mobile Geräte. Darüber hinaus zeigt der Modellvergleich, dass insbesondere Machine Learning Modelle präzise Vorhersagen des Online-Kundenverhaltens bei der Versicherung ermöglichen. Ein fundiertes Verständnis und eine möglichst genaue Vorhersage des Online-Kundenverhaltens basierend auf Kundendaten und in Abhängigkeit von zeitlichen Faktoren ist ein zentraler Baustein für die op-

Lukas Wolf, M.Sc. (Korrespondierender Autor)
Friedrich-Alexander Universität Erlangen-Nürnberg
Lehrstuhl für Betriebswirtschaftslehre, insb. Versicherungsmarketing
Lange Gasse 20
90403 Nürnberg
Mail: lukas.lw.wolf@fau.de
Elisabeth Galehr-Fritsch
Friedrich-Alexander University Erlangen-Nürnberg (FAU)
Lange Gasse 20
90403 Nürnberg
Deutschland
Martina Steul-Fischer
Friedrich-Alexander University Erlangen-Nürnberg (FAU)
Lange Gasse 20
90403 Nürnberg
Deutschland

timale Planung von Marketingmaßnahmen und die Steigerung der Customer Experience.

Abstract

Customers act differently depending on the time of day, day of the week, or season of the year. However, the influence of such temporal factors on customer behavior has hardly been researched so far. This study investigates the extent to which time effects exist in the online behavior of insurance customers (click behavior, insurance purchases, device choice) and whether time series models can predict specific customer behavior based on these time effects. The study uses a comprehensive clickstream dataset of a German insurer, which contains detailed mouse clicks of all website visitors over a period of two years. It shows that significantly fewer customers visit the website or purchase insurances on weekends and public holidays. The day-of-the-week effect is more pronounced when stationary devices are used compared to mobile devices. In addition, the model comparison shows that machine learning models in particular enable accurate predictions about online customer behavior in the insurance sector. A thorough understanding of online customer behavior, coupled with accurate predictions based on customer data and temporal factors, is a crucial element in the optimal planning of marketing strategies and enhancing the customer experience.

1. Einleitung

Online-Kanäle wie Anbieterwebseiten, Vergleichsportale oder Handy-Apps sind heute für viele Kunden die wichtigste Informationsquelle und werden nicht zuletzt seit der Corona-Krise immer häufiger auch für Versicherungskäufe genutzt. Um im wettbewerbsintensiven Umfeld der Versicherungsbranche erfolgreich zu sein, ist ein umfassendes Verständnis des Online-Kundenverhaltens sowie eine hohe Kundenzufriedenheit und positive Kundenerlebnisse (Customer Experience) unerlässlich (Barwitz 2020; Klopfer et al. 2022). Ein wesentlicher, aber bisher wenig beachteter Einflussfaktor auf das Online-Kundenverhalten ist die Zeit wie die Tageszeit, der Wochentag oder die Jahreszeit.

Zeitliche Faktoren gehen für viele Kunden mit gelernten Routinen einher (Ahlbom et al. 2023). Typischerweise gehen Kunden vormittags arbeiten, während sie abends entspannen, sich mit Freunden und Familie treffen oder anderen Aktivitäten nachgehen. In ähnlicher Art und Weise, unterscheiden sich auch die Routinen über die Wochentage und die Jahreszeiten hinweg. Das hat zur Folge, dass das Kundenverhalten maßgeblich von zeitlichen Faktoren beeinflusst wird. So sind Kunden beispielsweise unter der Woche oft gestresster und schlechter gelaunt als am Wochenende (Stone et al. 2012; Ahlbom et al. 2023). Außerdem verschiebt sich der Fokus vieler Kunden abhängig von Tageszeit, Wochentag und Jahreszeit (Bussi re 2011; Canova und Nicolini 2019). Zeiteffekte im Kundenverhalten lassen sich sowohl offline als auch im Internet beob-

achten, zum Beispiel beim Einkaufsverhalten im Supermarkt oder bei der Verwendung von Online-Preisvergleichsseiten (Canova und Nicolini 2019; Ahlbom et al. 2023). Beispielsweise hat der Wochentag einen Einfluss darauf, wie Kunden in Supermärkten auf Hintergrundmusik reagieren. Während am Wochenende die Musik einen neutralen bis negativen Effekt hat, sind an Werktagen positive Effekte auf das Einkaufsverhalten zu beobachten (Ahlbom et al. 2023). Bei Online-Käufen werden insbesondere montags Preise verglichen, um sich von der Arbeit abzulenken (Canova und Nicolini 2019). Zeitliche Faktoren scheinen darüber hinaus einen Einfluss auf die digitale Gerätewahl (PC, Smartphone, Tablet) für den Zugriff auf Online-Inhalte zu haben. Stationäre Geräte werden im Vergleich zu mobilen Geräten häufiger während der Arbeitszeit und an Werktagen genutzt (Park und Lee 2017; Haan et al. 2018; Canova und Nicolini 2019). Da sich Kunden im Internet unterschiedlich verhalten abhängig vom verwendeten digitalen Gerät (Wolf 2023), verstärkt der Einfluss zeitlicher Faktoren auf die Gerätewahl den Einfluss von Zeiteffekten im Kundenverhalten potenziell weiter.

Trotz einzelner Studien, die einen Einfluss des Wochentags auf das Kundenverhalten allgemein aufzeigen (z. B. Bussière 2011) oder einen temporalen Einfluss im Online-Handel auf die präferierte Geräteauswahl beobachten (z. B. Haan et al. 2018), fehlt ein ganzheitlicher Überblick über Zeiteffekte im Online-Kundenverhalten. Außerdem liegt der Fokus bisheriger Untersuchungen zu Zeiteffekten im Kundenverhalten auf Konsumgütern wie Lebensmittel oder Mode (Namin und Dehdashti 2019; Albrecht et al. 2021; Ahlbom et al. 2023). Der Versicherungssektor wurde dagegen bisher kaum beachtet, obwohl die Optimierung der Customer Experience durch ein Verständnis von Kundenverhalten aufgrund des hohen Wettbewerbsdrucks, der geringen Markenbindung und geringer Möglichkeiten sich durch Produktinnovationen abzuheben, in diesem Markt von unschätzbarem Wert ist (Barwitz 2020; Klopfer et al. 2022). Diese Studie untersucht daher, (1) inwiefern unterschiedliche Zeiteffekte (Wochentag, Feiertag, Jahreszeit) im Online-Verhalten von Versicherungskunden (Klickverhalten, Versicherungskäufe, Gerätewahl) bestehen und (2) ob Machine Learning Modelle auf Basis dieser Zeiteffekte spezifisches Kundenverhalten (Online-Versicherungskäufe) präziser vorhersagen können als gängige Zeitreihenmodelle. Grundlage der deskriptiven Analyse und der Voraussage ist ein umfassender Clickstream-Datensatz eines großen deutschen Versicherers, der die detaillierten Mausklicks aller Webseitenbesucher über zwei Jahre beinhaltet. Ein fundiertes Verständnis und eine möglichst genaue Voraussage des zukünftigen Online-Kundenverhaltens basierend auf Kundendaten und in Abhängigkeit von zeitlichen Faktoren ist ein zentraler Baustein für die optimale Planung von Marketingmaßnahmen sowie die Steigerung der Customer Experience (Holmlund et al. 2020).

Die vorliegende Studie ist wie folgt gegliedert: In Kapitel 2 werden theoretische Grundlagen zum Einfluss von zeitlichen Faktoren auf das Kundenverhalten aufgezeigt. Anschließend werden in Kapitel 3 die Datengrundlage und die Methode vorgestellt sowie in Kapitel 4 die deskriptiven Ergebnisse und die analysierten Zeiteffekte abgebildet. Auf Basis dieser Zeiteffekte wird in Kapitel 5 das Kundenverhalten prognostiziert und ein Modellvergleich zwischen zwei etablierten Zeitreihenmodellen (ARIMA und SARIMA) und verschiedener Machine Learning Modelle (K-Nearest-Neighbor, lineare Regression, Ridge Regression, Random Forest und (Stochastic) Gradient Boosting) vorgenommen (Albrecht et al. 2021; Taylor 2008). Nach der Darstellung der Ergebnisse werden in Kapitel 6 die theoretischen und praktischen Implikationen der Erkenntnisse diskutiert und Ansätze für zukünftige Forschung vorgeschlagen.

2. Einfluss von zeitlichen Faktoren auf Kundenverhalten

Unter Zeiteffekten verstehen wir in dieser Studie den Einfluss zeitlicher Faktoren wie Tageszeit, Wochentag, oder Jahreszeit auf das Kundenverhalten. Tabelle 1 im Anhang gibt einen Überblick über bisherige Studien, die den Einfluss von zeitlichen Faktoren auf das Kundenverhalten untersucht haben und somit Zeiteffekte aufzeigen.

Der am häufigsten untersuchte Zeiteffekt ist der Einfluss des Wochentages auf das Kundenverhalten (engl. *Day-of-the-Week Effect*). Kunden lassen abhängig vom Wochentag unterschiedliche Stimmungen und Stresslevel erkennen. Stone et al. (2012) beobachten in einer großangelegten Telefonumfrage mit über 300.000 amerikanischen Teilnehmern beispielsweise, dass sich die Stimmung von Konsumenten abhängig vom Wochentag signifikant unterscheidet. Am Wochenende und freitags weisen Kunden tendenziell mehr positive Gefühle und weniger negative auf als unter der Woche. In ähnlicher Weise zeigen Ahlbom et al. (2023), dass Einkäufer in Supermärkten an Werktagen im Vergleich zum Wochenende ausgelaugter und gestresster sind und sich folglich unter der Woche anders verhalten. Auch Namin und Dehdashti (2019) weisen einen signifikanten Einfluss des Wochentags auf das Kundenverhalten in Einkaufsläden nach. Insbesondere demonstrieren die Autoren, dass sich verschiedene Kundengruppen unterscheiden lassen, die an bestimmten Wochentagen einkaufen. Beispielsweise kaufen Kunden mit sehr hohem Einkommen und fester Arbeitsstelle Haushaltsprodukte (z.B. Waschmittel) eher samstags, wohingegen Kunden der unteren Mittelklasse diese Produkte vermehrt sonntags kaufen. Durch Anpassung von Sortiment, Preismanagement und Bewerbung an Kundenbedürfnisse abhängig von Wochentagen lassen sich somit die Customer Experience steigern und höhere Gewinne generieren (Ahlbom et al. 2023; Namin und Dehdashti 2019).

Der Day-of-the-Week Effect lässt sich auch im Internet beobachten. So befassen sich Kunden im Internet am Wochenende mit anderen Produktkategorien als unter der Woche. Werktags beschäftigen sich Kunden eher mit zweck- bzw. nutzenorientierten Themen wie Versicherungen und Investitionen, während sich der Fokus am Wochenende von solch utilitaristischen Produkten zu hedonistischen Produkten wie Unterhaltung, Essen und Trinken oder Urlaub verschiebt (Bussière 2011). Canova und Nicolini (2019) argumentieren darüber hinaus, dass Kunden während der Arbeitswoche und insbesondere am Montag, ein Verhalten namens „Cyberslacking“ zeigen, bei dem sie viel Zeit auf der Arbeit damit verbringen, das Internet für persönliche Zwecke zu nutzen. Die Autoren zeigen auf der Grundlage dieser Argumentation, dass Kunden unter der Woche signifikant häufiger im Internet Preise vergleichen als am Wochenende. Dieser Wochentageffekt auf die Online-Preissuche wird durch die Gerätewahl weiter verstärkt. So findet in der Studie die Preissuche insbesondere über stationäre Geräte wie Laptops und PCs statt. Diese werden bevorzugt werktags und weniger am Wochenende für Online-Aktivitäten genutzt, während die Präferenz für mobile Geräte kaum vom Wochentag beeinflusst wird (Canova und Nicolini 2019). Andere Studien beobachten einen ähnlichen Einfluss von Zeitfaktoren auf die Wahl digitaler Geräte im Internet. Park und Lee (2017) und Haan et al. (2018) zeigen beispielsweise, dass stationäre Geräte im Vergleich zu mobilen Geräten häufiger während der Arbeitszeit und an Werktagen genutzt werden. Tablets werden dagegen häufiger am Wochenende gewählt, während der Wochentag weniger Einfluss auf die Nutzung von Smartphones hat (Park und Lee 2017; Haan et al. 2018; Canova und Nicolini 2019).

Ein weiterer zeitlicher Faktor neben Tageszeit und Wochentag ist die Jahreszeit. Die vier meteorologischen Jahreszeiten (Winter, Frühling, Sommer, Herbst) unterscheiden sich hauptsächlich durch Veränderungen in der Temperatur, der Menge an Tageslicht, dem Wetter und der Vegetation. Kunden reagieren auf diese saisonalen Unterschiede mit Änderungen hinsichtlich Kauf-, Freizeit- und Reiseverhalten. Zum Beispiel beobachten Canova und Nicolini (2019) eine Zunahme der Onlineaktivität in den Monaten vor Weihnachten und in Jahreszeiten mit schlechterem Wetter. Zhang et al. (2022) zeigen, dass Online-Kunden in Monaten außerhalb der Ferienzeit (zwischen April und Mai) auf andere Qualitätsaspekte der Webseite stärker achten als in der Ferienzeit (zwischen November und Dezember).

Diese Studien veranschaulichen eindrucksvoll, dass Unternehmen bei der Analyse von Kundendaten und bei der Planung von Marketingaktivitäten und Verkaufsstrategien Zeiteffekte berücksichtigen sollten. Gleichzeitig fehlt in der bisherigen Literatur ein Überblick über den Einfluss von zeitlichen Faktoren auf das Online-Kundenverhalten allgemein und auf den Versicherungsmarkt im Besonderen (siehe Tabelle 1). Die vorliegende Studie zielt daher darauf ab, die Zei-

teffekte beim Online-Kundenverhalten im Versicherungsbereich zu untersuchen. Auf Grundlage der diskutierten Studien vermuten wir, dass sich Versicherungskunden abhängig vom Wochentag und der Jahreszeit unterschiedlich verhalten. In Anlehnung an die Studien von Bussière (2011) und Canova und Nicolini (2019) gehen wir davon aus, dass am Wochenende und im Frühling und Sommer weniger Versicherungskunden die Anbieterwebseite besuchen oder eine Versicherung abschließen. Wir untersuchen außerdem den Einfluss von Feiertagen auf das Online-Kundenverhalten und berücksichtigen die Wahl digitaler Geräte in Abhängigkeit zeitlicher Faktoren.

3. Datengrundlage und Methode

Grundlage dieser Studie ist ein entpersonalisierter, auf Wochentagbasis aggregierter Clickstream-Datensatz eines großen deutschen Versicherers. Dieser Datensatz umfasst die detaillierte Aufzeichnung der Mausklicks von über 32 Millionen Besuchern der Webseite des Versicherers in einem zweijährigen Zeitraum vom 01. Juli 2019 bis zum 31. Juli 2021 (762 Tage). Neben Informationen zu den angeklickten Seiten während eines Besuchs (z.B. Besuch einer Landingpage oder Produktseite), beinhaltet der Datensatz Informationen zu Online-Versicherungskäufen und dem verwendeten digitalen Gerät. Die Anbieterwebseite von Versicherungen ist die am häufigsten genutzte Anlaufstelle für Kunden, um sich über Versicherungen zu informieren – noch vor Vergleichsportalen und Versicherungsmaklern bzw. Vermittlern vor Ort (Adesso SE 2023). Dies unterstreicht die Eignung des Datensatzes für die Analyse von Online-Kundenverhalten im Versicherungsbereich.

Für die deskriptive Analyse werden die durchschnittlichen Besucher- und Kaufzahlen (Abschluss einer Versicherung online) auf der Webseite abhängig vom Wochentag betrachtet. Anschließend werden die Unterschiede zwischen Werktagen (Montag bis Freitag) und Wochenende (Samstag und Sonntag) mithilfe von t-Tests verglichen. Des Weiteren werden die Unterschiede zwischen Feiertagen und „normalen“ Tagen aufgezeigt und ebenfalls mithilfe von t-Tests gegenübergestellt. In dem zweijährigen Zeitraum der Daten fallen insgesamt 18 gesetzliche Feiertage, wovon 15 unter der Woche und drei an Samstagen stattfanden.¹ Zuletzt werden die Unterschiede für durchschnittliche Besucher- und Kaufzahlen zwischen den vier meteorologischen Jahreszeiten Winter (01.12.–28./29.02.), Frühling (01.03.–31.05.), Sommer (01.06.–31.08.) und Herbst (01.09.–30.11.) mithilfe einer einfaktoriellen Varianzanalyse (ANOVA) analysiert. Zusätzlich wird aufgezeigt, inwieweit sich die Gerätewahl (Smartphone,

¹ Konkret wurden folgende bundesweite, deutsche Feiertage ausgewählt: Neujahr, Karfreitag, Ostern, Ostermontag, Tag der Arbeit, Christi Himmelfahrt, Pfingstmontag, Tag der deutschen Einheit, Weihnachten und zweiter Weihnachtsfeiertag.

Tablet, PC oder Laptop) für den Besuch bzw. den Abschluss einer Versicherung im Internet abhängig von Wochentag, Feiertag und Jahreszeit unterscheidet.

Auf Grundlage der beobachteten Zeiteffekte und Unterschiede in der Gerätewahl in den Clickstream-Daten wird im Anschluss ein Modellvergleich verschiedener Zeitreihenmodelle und Machine Learning Modelle vorgenommen, um Online-Versicherungskäufe vorherzusagen. Zeitreihenmodelle werden auf Basis historischer Zeitreihendaten trainiert. Das Ziel besteht darin, die zugrundeliegende Struktur der Zeitreihe zu erkennen, zu verstehen und anschließend von ihren verborgenen Eigenschaften nützliche Informationen für die Vorhersage zukünftiger Daten abzuleiten (Lazzeri 2021). Die Effizienz und die Leistung von Voraussagemodellen ist abhängig von den zugrundeliegenden Daten und der Prognoseaufgabe. Deswegen müssen verschiedene Modelle verglichen werden, um das Verfahren mit der besten Prognosegüte zu finden (Taylor 2008; Albrecht et al. 2021). In dieser Studie werden zwei etablierte Zeitreihenmodelle (Auto-Regressive Integrated Moving Average (ARIMA) und Seasonal-ARIMA (SARIMA)) und fünf verschiedene Machine Learning Modelle (K-Nearest-Neighbor (KNN), lineare Regression, Ridge Regression, Random Forest und (Stochastic) Gradient Boosting (SGB)) trainiert und getestet (Albrecht et al. 2021). Die Voraussage von Online-Kundenverhalten mithilfe von Machine Learning Modellen auf Basis von Clickstream-Daten wurde bereits erfolgreich für andere Anwendungsfelder, wie der Voraussage von Warenkorbabbrechern, angewandt (Rausch et al. 2022).


4. Deskriptive Analyse

Im Rahmen der deskriptiven Analyse der Daten wurde insbesondere der Einfluss unterschiedlicher Wochentage, Feiertage und der meteorologischen Jahreszeit auf das Klickverhalten untersucht und mögliche Zeiteffekte bei der präferierten Gerätewahl betrachtet (siehe Abbildung 1). Bezüglich des Wochentageffekts auf das Online-Kundenverhalten bestätigen die Ergebnisse weitgehend die bisherigen Beobachtungen aus der Marketingforschung (z. B. Bussière 2011; Canova und Nicolini 2019). So werden an Werktagen durchschnittlich deutlich mehr Besucher der Webseite und Online-Versicherungskäufe verzeichnet als am Wochenende ($p < 0,001$, Cohen's $d = 0,52$ (Besucher); $p < 0,001$, Cohen's $d = 0,30$ (Käufe)). Am Wochenende, insbesondere samstags, ist die Anzahl an Besuchern und Käufen signifikant geringer als unter der Woche. Die höchste durchschnittliche Besucherzahl wird am Dienstag registriert (durchschnittlich 48.091 Besucher pro Tag), die meisten Versicherungen werden montags auf der Webseite abgeschlossen (durchschnittlich 250 Onlineabschlüsse pro Tag). Der Vergleich von Feiertagen und Nicht-Feiertagen impliziert ein ähnliches Verhaltensmuster an Feiertagen wie an Wochenenden und die Webaktivität ist somit deutlich geringer

($p < 0,001$, Cohen's $d = 0,88$ (Besucher); $p < 0,05$, Cohen's $d = 0,44$ (Käufe)). Die Überprüfung saisonaler Trends im Zeitverlauf zeigt ebenfalls signifikante, allerdings effekt-schwache Unterschiede zwischen meteorologischen Jahreszeiten ($p < 0,001$, $\eta^2 = 0,065$ (Besucher); $p < 0,001$, $\eta^2 = 0,007$ (Käufe)). So werden im Sommer weniger Besucher und im Frühling weniger Versicherungskäufe verzeichnet. Eine ergänzende Auswertung deutet außerdem auf Unterschiede zwischen den Versicherungsprodukten hin. Reiseversicherungen werden beispielsweise signifikant häufiger im Sommer als in allen anderen Jahreszeiten abgeschlossen ($p < 0,001$), andere Versicherungen wie Sterbegeld werden dagegen signifikant häufiger im Herbst abgeschlossen ($p < 0,05$).

Zusätzlich zeigt die deskriptive Auswertung, dass die untersuchten Zeitfaktoren wie vermutet einen Einfluss auf die Gerätewahl haben (siehe Abbildung 1). Gemäß der Literatur (z.B. Haan et al. 2018) werden stationäre Geräte wie PCs und Laptops (zusammengefasst unter „PC“) allgemein häufiger für den Abschluss von Versicherungen genutzt als mobile Geräte wie Smartphones oder Tablets (53,35 % der Online-Versicherungskäufe erfolgen über den PC). Im Gegensatz dazu werden mobile Geräte häufiger für den Besuch der Webseite verwendet (56,65 % der Besuche erfolgen über mobile Geräte). Wie bereits von vorherigen Studien impliziert (Park und Lee 2017; Haan et al. 2018; Canova und Nicolini 2019) werden stationäre Geräte allerdings signifikant seltener am Wochenende und an Feiertagen für den Besuch der Webseite und den Abschluss von Versicherungen gewählt als unter der Woche. Sowohl für die durchschnittliche Besucherzahl als auch für die durchschnittlichen Kaufzahlen über stationäre Geräte sind die Unterschiede zwischen Werktag und Wochenende hochsignifikant ($p < 0,001$, Cohen's $d = 0,72$ (Besucher); $p < 0,001$, Cohen's $d = 0,89$ (Käufe)). Bei der Betrachtung der Smartphone- und Tablet-Nutzung fällt dagegen auf, dass diese vom Wochentag weniger beeinflusst werden. Ein signifikanter Unterschied zwischen Wochenende und Werktagen lässt sich hier nur für die durchschnittlichen Besucherzahlen über das Smartphone feststellen (wenngleich mit kleinerer Effektstärke: $p < 0,001$, Cohen's $d = 0,32$). Hinsichtlich der Käufe über das Smartphone, bzw. für Besuche und Käufe über das Tablet ist der Unterschied nicht signifikant. Infolgedessen dreht sich für Online-Versicherungskäufe am Wochenende und an Feiertagen sogar das Verhältnis in der Gerätewahl und es werden anteilig häufiger mobile Geräte für den Kauf genutzt als stationäre Geräte. Samstags und sonntags werden beispielsweise nur 43 % der Online-Versicherungskäufe über stationäre Geräte durchgeführt.²

² Die signifikanten Unterschiede zwischen zeitlichen Faktoren sind in ähnlicher Ausprägung in den Daten für den Zeitraum vor der Corona-Pandemie (01.07.2019–21.03.2020) und während der Corona-Pandemie und damit verbundenen Maßnahmen in Deutschland (22.03.2020–31.07.2021) erkennbar. Insbesondere sind die durchschnittlichen Besucher- und Kaufzahlen an Werktagen in beiden Zeiträumen signifikant höher als am Wochenende. Darüber hinaus wird in beiden Zeiträumen unter der Woche im Vergleich zum Wo-



Anmerkung: Standardfehler für alle Besuche und Käufe sind in den Fehlerbalken angegeben.

Abb. 1: Durchschnittliche Anzahl von (a) Besuchern und (b) Käufen und die Gerätenutzung abhängig von der Zeit (Wochentag, Wochenende, Feiertag, Jahreszeit)

chenende anteilig häufiger der PC für Versicherungskäufe genutzt, während das Smartphone am Wochenende bevorzugt wird. Es ist jedoch zu beachten, dass in dem Zeitraum vor Corona nur vier Feiertage in den Daten enthalten sind und die Angaben zu den Jahreszeiten aufgrund eingeschränkter Daten ebenfalls nur begrenzt aussagekräftig sind.

5. Ergebnisse des Modellvergleichs

Auf Basis der aufgezeigten Zeiteffekte im Online-Kundenverhalten können Versicherer zukünftiges Kundenverhalten (z. B. Online-Versicherungskäufe) prognostizieren und damit ihre Marketingmaßnahmen und ihren Ressourceneinsatz optimieren. Albrecht et al. (2021) zeigen zum Beispiel in einem Vergleich von Vorhersagemodellen auf, dass die Anrufprognose in Call Centern auf Basis von Zeiteffekten zu signifikanten Einsparungen beim Personal führen kann. Für eine Prognose mithilfe von Vorhersagemodellen bieten sich dabei insbesondere Machine Learning Modelle an, da diese im Vergleich zu gängigen Zeitreihenmodellen häufig genauere Vorhersagen treffen (Albrecht et al. 2021; Barrow 2016). Der zweite Teil der Studie beschäftigt sich daher mit der Vorhersage von Online-Versicherungskäufen mithilfe von Machine Learning Modellen.

Als unabhängige Variablen für die prädiktive Analyse dienen verschiedene, in der deskriptiven Analyse ermittelte Zeiteffekte sowie die relative Gerätenutzung (Desktop vs. Smartphone), um Online-Versicherungskäufe (abhängige Variable) vorherzusagen. Die anschließende Vorhersage erfolgt mittels folgender Machine Learning Verfahren: KNN, lineare Regression, Ridge Regression, Random Forest und SGB (Pedregosa et al. 2011).³ Diese fünf Modelle ermöglichen eine hohe Flexibilität bei gleichzeitig guter Interpretierbarkeit und sind damit für eine Umsetzung in der Praxis gut geeignet (James et al. 2021). Als Vergleichsmodelle wurden mit dem ARIMA und SARIMA-Modell zwei etablierte und in der Literatur und Praxis häufig genutzte Zeitreihenmodelle herangezogen. Beide Modelle erstellen auf Basis zurückliegender Beobachtungen Vorhersagen über zukünftige Ereignisse und ermöglichen eine besonders hohe Flexibilität bei der Modellanpassung, da sie sowohl autoregressive als auch gleitende Mittelwertbeitrags-Prozesse miteinander vereinen. Das SARIMA-Modell berücksichtigt außerdem saisonale Muster in den Zeitreihen (Box 2016; Box et al. 2008; Hyndman und Athanasopoulos 2018). Als Grundlage für den empirischen Modellvergleich wurden alle Tage (762) im gesamten Untersuchungszeitraum (01. Juli 2019–31. Juli 2021) mit Ausnahme von insgesamt fünf Ausreißern, die mehr als 500 Versicherungskäufe pro Tag aufgrund vermutlich einzelner Werbemaßnahmen enthalten, herangezogen. Somit umfasst der analysierte Datensatz insgesamt 757 Tage mit 12 erklärenden Variablen (jeweils eine Dummy-Variable für jeden Wochentag, für jede Jahreszeit, sowie der relativen Gerätenutzung an dem betrachteten Tag). Der Verlauf der Online-Versicherungskäufe über den untersuchten Zeitraum nach der Elimination der Ausreißer ist in Abbildung 2 dargestellt.

³ Für eine ausführliche Erläuterung der Methoden ARIMA und des maschinellen Lernens siehe Albrecht et al. (2021). Da für die Praxis bei der Implementierung von Prognosemodellen Verständlichkeit und deren vergleichsweise einfache Umsetzung eine große Rolle spielt, werden in dieser Arbeit Support Vector Machines und Deep Learning ausgeschlossen.




Abb. 2: Online-Versicherungskäufe über den untersuchten Zeitraum (ohne Ausreißer)

Zur Validierung und Evaluierung der angewandten Modelle wird eine Kreuzvalidierung mit einem Expanding-Rolling-Window verwendet (Albrecht et al. 2021). Dabei werden die jeweiligen Modelle mit verschiedenen Hyperparametern unter Verwendung der historischen Zeitreihendaten im Datensatz trainiert. Anschließend gibt das Modell für einen bestimmten Vorhersagehorizont (z.B. eine Woche) eine Voraussage ab und die Prognosegüte wird berechnet. Bei der nächsten Iteration „rollen“ die Trainings- und Testdaten um den gewählten Vorhersagehorizont weiter und die Prognosegüte wird erneut berechnet. Diese Prozedur wird so lange wiederholt, bis für jeden Teildatensatz das Modell angepasst und die Prognosegüte bestimmt ist. Der Mittelwert der Prognosefehler über alle Teildatensätze hinweg zeigt abschließend die durchschnittliche Abweichung der Prognose von den Originaldaten an. In dieser Studie wird für die Vorhersage jeweils ein Vorhersagehorizont von einer und zwei Wochen gewählt und die daraus resultierenden Prognosefehler miteinander verglichen. Da die Modelle ohne Vorlaufzeit (Lead Time) trainiert werden, gibt es 108 Iterationen bei einer Woche als Vorhersagehorizont und 54 bei zwei Wochen (entspricht 757 Tagen).

Die jeweilige Modellperformance wurde mithilfe des Root-Mean-Squared-Error (RMSE) und Mean-Absolute-Error (MAE) gemessen. Diese beiden skalenabhängigen Prognosefehler messen den durchschnittlichen Fehler, den man von der Vorhersage erwarten kann, wobei niedrige Werte grundsätzlich ein Indikator für eine hohe Prognosegüte sind. Konkret berechnen sich die beiden Metriken wie folgt:

$$MAE = \frac{1}{T} \sum_{i=1}^T |Y_i - \hat{Y}_i|$$

$$RMSE = \sqrt{\frac{1}{T} \sum_{i=1}^T (Y_i - \hat{Y}_i)^2}$$

Dabei entspricht Y_i dem Testset, $\hat{Y}_i$ den vom Modell vorhergesagten Werten und T der Anzahl der vorhergesagten Werte (Hyndman und Athanasopoulos 2018; Albrecht et al. 2021; Taylor 2008). Vereinfacht gesagt, drücken beide Metriken aus, welcher durchschnittliche Fehler von der Prognose zu erwarten ist, wobei der RMSE durch die Quadrierung größere Abweichungen stärker bestraft und deshalb immer mindestens gleich groß ausfällt wie der MAE.

Aus dem Modellvergleich geht hervor, dass im Einklang mit der Literatur die verwendeten Machine Learning Modelle wesentlich genauere Prognosen liefern als etablierte Zeitreihenmodelle (siehe Abbildung 3). Dies wird nachfolgend exemplarisch an einem Vorhersagehorizont von einer Woche gezeigt. Während das ARIMA-Modell bei einem Vorhersagehorizont von einer Woche einen RMSE (MAE)-Wert von 70,83 (59,77) aufweist und das SARIMA Modell einen RMSE (MAE)-Wert von 60,93 (51,23), lagen RMSE-Werte bei allen angewendeten Machine Learning-Algorithmen zwischen 37,37 und 39,78 (MAE: 32,24 und 33,81). Konkret bedeutet dies, dass im Falle des ARIMA-Modells die Käufe im Durchschnitt um 70,83 (59,77) Käufe von den wahren Käufen abweichen, und dieser Prognosefehler bei den betrachteten Machine Learning Modellen fast halbiert wird. Das beste Ergebnis sowohl für einen Vorhersagehorizont von einer als auch von zwei Wochen liefert die Ridge Regression (RMSE für eine Woche: 37,37; RMSE für zwei Wochen: 39,32).⁴ Abbildung 4 veranschaulicht die Performance der einzelnen Modelle beispielhaft in der Kalenderwoche 34 in 2020.

⁴ Die Betrachtung der einzelnen Modelle im Zeitverlauf für jedes Expanding-Rolling-Window zeigt, dass sich das Random Forest Modell besonders bei starken Schwankungen in den Daten wie beispielsweise zwischen Ende 2019 bis April 2020 gegen die sonst überlegenen Modelle SGB oder Ridge Regression durchsetzt hinsichtlich der Prognosegüte. Außerdem ist die Differenz der MAE- und RMSE-Werte für einen Vorhersagehorizont von einer und zwei Wochen am geringsten für das Random Forest Modell. Dieses Modell scheint daher am besten geeignet für Daten, die starken Schwankungen unterliegen und über einen längeren Zeitraum vorhergesagt werden sollen. Dies hebt hervor, dass die Prognosegüte der Modelle stark abhängt von der Datengrundlage und ein Modellvergleich zwischen verschiedenen Machine Learning Modellen zu empfehlen ist.




Abb. 3: Modellvergleich unter Betrachtung von **(a)** MAE- und **(b)** RMSE-Werten für einen Vorhersagehorizont von einer Woche und zwei Wochen




Abb. 4: Graphischer Modellvergleich über beispielhaftem 7 Tage-Intervall in KW 34 in 2020

6. Diskussion der Ergebnisse und Ausblick

Die Ergebnisse der vorliegenden Studie verdeutlichen, dass das Online-Kundenverhalten bei Versicherungen wochenend-, feiertags- und jahreszeitspezifischen Effekten unterliegt. Damit stellen diese Erkenntnisse für die Praxis einen wichtigen Ausgangspunkt für die zielgerichtete Kundenansprache sowie der Steigerung des Kundenerlebnisses an jedem Berührungspunkt entlang der Customer Journey dar (Holmlund et al. 2020; Lemon und Verhoef 2016). Ferner erlaubt die Vorhersage von Versicherungskäufen mithilfe von Machine Learning Modellen auf Basis der Zeiteffekte wesentlich genauerer Prognosen als etablierte Zeitreihenmodelle wie das ARIMA- oder das SARIMA-Modell. Dadurch können Versicherer ihren Ressourceneinsatz besser planen und schneller auf Kundenanliegen reagieren und damit die Kundenzufriedenheit steigern. Zudem können auch Kommunikationsmaßnahmen und Preisstrategien an Zeiteffekte angepasst werden. Die Ergebnisse dieser Studie liefern daher wertvolle Erkenntnisse für ein erfolgreiches Customer Experience Management von Versicherungsunternehmen und Anhaltspunkte für weitere Forschung in diesem Bereich.

Theoretische Implikationen und Forschungsausblick: Die deskriptive Analyse der Daten offenbart, dass am Wochenende, an Feiertagen sowie im Frühling und Sommer signifikant weniger Kunden pro Tag die Webseite besuchen und eine Versicherung online abschließen. Damit zeigt diese Studie, dass auch im Versicherungsbereich signifikante Zeiteffekte im Online-Verhalten beobachtet werden können. Bei einer genaueren Betrachtung der Gerätewahl abhängig von zeitlichen Faktoren, wird darüber hinaus deutlich, dass solche Zeiteffekte insbesondere bei der Wahl von stationären Geräten eine wichtige Rolle spielen und weniger Einfluss auf die Wahl mobiler Geräte haben. Dies führt dazu, dass stationäre Geräte nur unter der Woche häufiger als mobile Geräte für einen Online-Versicherungskauf genutzt werden. Am Wochenende nutzen Kunden dagegen anteilig vermehrt mobile Geräte für den Abschluss von Versicherungen. Dies widerspricht dem allgemeinen Forschungskonsens, dass mobile Geräte generell seltener für den Online-Kauf genutzt werden als stationäre Geräte (z. B. Haan et al. 2018; Rausch et al. 2022), und verdeutlicht eindrucksvoll den Einfluss zeitlicher Faktoren.

Die vorliegende Studie veranschaulicht außerdem, dass das Online-Kundenverhalten sehr gut anhand von zeitlichen Faktoren vorhergesagt werden kann. So können auf Basis der Daten Prognosen durchgeführt werden, die über eine Annahme eines zeitunabhängigen Durchschnitts hinausgehen. Insbesondere Machine Learning Modelle zeigen hierbei eine gute Performance (siehe Abbildungen 3 und 4). Hierbei ist anzumerken, dass der Datensatz einige Limitationen aufweist. Zum einen sind die Daten lediglich auf Wochentagbasis aggregiert

und auf wenige Metriken reduziert (nur 12 Prädiktoren). Zum anderen umfasst der Datensatz den Zeitraum der Corona-Pandemie, was einen umfassenden Einfluss auf das Verhalten der Kunden hatte. Zukünftige Studien sollten als weiteren zeitlichen Faktor die Tageszeit aufnehmen, die ebenfalls einen Einfluss auf Kundenverhalten hat (Albrecht et al. 2021; Ahlbom et al. 2023). Außerdem sollte untersucht werden, inwieweit sich die Kunden unterscheiden, die zu unterschiedlichen Zeiten auf die Webseite zugreifen. Der zugrundeliegende Datensatz ermöglicht keine Aussage darüber, ob die beobachteten Zeiteffekte auf Selbst-Selektion zurückzuführen sind (d. h. unterschiedliche Kunden greifen zu unterschiedlichen Zeiten auf die Webseite zu) oder ob zeitliche Faktoren das Kundenverhalten direkt beeinflussen.

Praktische Implikationen: Zeitliche Faktoren sind für das Management leichter zu operationalisieren als unterschiedliche Kundenbedürfnisse. Mit dem ersten Klick auf die Webseite ist klar, um welche Uhrzeit, welchen Wochentag und welche Jahreszeit es sich handelt und ob der Zugriff an einem Feiertag erfolgt. Mit einem umfassenden Wissen inwieweit sich Kundenbedürfnisse abhängig von solchen zeitlichen Faktoren unterscheiden, können somit Marketingmaßnahmen (Gestaltung der Webseite, Bewerbung bestimmter Produkte, Preismanagement) angepasst werden, um mit Kundenpräferenzen im Einklang zu sein und effektiv das Kundenverhalten zu beeinflussen. Beispielsweise könnte das Wissen, dass unter der Woche stationäre Geräte häufiger für den Online-Versicherungskauf verwendet werden als mobile Geräte, genutzt werden, um den Gerätewechsel entlang der Customer Journey insbesondere an Werktagen zu erleichtern (Haan et al. 2018). Am Wochenende und an Feiertagen könnten dagegen Benachrichtigungen an gestartete Kaufprozesse auf mobile Geräte gesendet oder das Suchmaschinenmarketing insofern optimiert werden, dass insbesondere Smartphone-Nutzer Anzeigen zu Versicherungskäufen zugespielt bekommen. Aufbauend auf die untersuchten Zeiteffekte können außerdem, wie in dieser Studie aufgezeigt, Vorhersagen zu Verhaltensweisen von Kunden getroffen werden. Darüber hinaus können diese Erkenntnisse zur Optimierung der Customer Experience eingesetzt werden, indem zum Beispiel der Personaleinsatz entsprechend optimiert wird.

Die Vorhersage in dieser Studie wurde auf Basis eines entpersonalisierten und auf Wochentagbasis aggregierten Datensatzes, der nur wenige Metriken beinhaltet, durchgeführt. Umso beeindruckender ist die gute Vorhersagegüte. Unter Einbezug weiterer Metriken (z. B. nutzerbezogener Daten) könnte die Vorhersagegüte noch weiter gesteigert werden. Der Modellvergleich in dieser Studie zeigt exemplarisch auf, wie Versicherungsunternehmen aufbauend auf Zeiteffekte Online-Kundenverhalten präzise vorhersagen können. Ähnliche Modelle könnten in gleicher Weise für andere Verhaltensweisen trainiert und eingesetzt werden. Neben Online-Versicherungskäufen allgemein könnten beispielsweise pro-

dukt-spezifische Abschlüsse oder Schadensmeldungen vorhergesagt werden, um den Kundenservice auf diese Anfragen vorzubereiten. Alternativ könnte auch prognostiziert werden, wann die Webseite verlassen und der Berater vor Ort kontaktiert wird. Basierend hierauf könnten Versicherungsvertreter vor Ort wiederum ihr Personalmanagement gestalten.

Anhang

Tab. 1

Vergleich bisheriger Studien zum Einfluss von zeitlichen Faktoren auf Kundenverhalten mit der vorliegenden Studie

Autor (Jahr)	Titel	Fokus	Datenbasis	Methode	Untersuchter zeitl. Faktor	Wesentliches Ergebnis hinsichtlich Zeiteffekte
Ahlboom et al. (2023)	Understanding how music influences shopping on weekdays and weekends	Untersuchung des Einflusses von Musik auf Kaufverhalten in Supermärkten	Semi-strukturierte Experten- und Kundeninterviews, Feld- und Laborexperimente	Meta-Analyse, Kovarianzanalyse (ANCOVA), Mediationsanalyse	Tageszeit, Werktag vs. Wochenende	- Kunden sind erschöpfter und gestresster an Werktagen als am Wochenende - Unter der Woche hat außerdem die Tageszeit einen Einfluss auf das Stresslevel; am Wochenende nicht - Musik in Supermärkten hat unter der Woche einen positiven Einfluss auf Einkaufsverhalten und einen neutralen bis negativen am Wochenende
Albrecht et al. (2021)	Call me maybe: Methods and practical implementation of artificial intelligence in call center arrivals' forecasting	Voraussage von Anrufen beim Call Center eines Onlinehändlers für Mode	Anruf-Daten	Machine Learning-basierte Zeitreihenmodelle	Tageszeit, Wochenentag, Feiertage	- Montags gibt es die meisten Anrufe im Call Center des untersuchten Onlinehändlers, samstags die wenigsten - Die meisten Anrufe gehen über alle Tage hinweg morgens und nachmittags ein

(Fortsetzung nächste Seite)

(Fortsetzung Tab. 1)

Autor (Jahr)	Titel	Fokus	Datenbasis	Methode	Untersuchter zeitl. Faktor	Wesentliches Ergebnis hinsichtlich Zeiteffekte
Bussière (2011)	The day of the week effect in consumer behavior: analyzing utilitarian and hedonistic consumer modes	Untersuchung des Wochentag-Einflusses auf den täglichen Internetverkehr auf unterschiedlichen Webseiten	Online-Aktivitäts-Daten	Regressionsanalyse	Wochentag	• Menschen greifen auf unterschiedliche Arten von Webseiten zu an verschiedenen Tagen der Woche • Werktags befassen sich Kunden eher mit utilitaristischen Produkten und Themen und am Wochenende häufiger mit hedonistischen Produkten und Themen
Canova und Nicolini (2019)	Online price search across desktop and mobile devices: Evidence on cyberslacking and weather effects	Untersuchung von Preissuche im Internet auf einer Vergleichsplattform	Clickstream-Daten	Ökonometrische Modelle (Panel fixed effects specification)	Wochentag, Monat im Jahr	• Preissuchen im Internet finden häufiger an Werktagen und insbesondere montags statt • Der Wochentag beeinflusst die Gerätewahl • Die Jahreszeit beeinflusst Preissuchen im Internet insofern, dass in den Monaten vor Weihnachten mehr gesucht wird • Außerdem beeinflussen Wetterbedingungen, die direkt von Jahreszeiten abhängen, die Preissuche
Namin und Dehdashi (2019)	A „hidden“ side of consumer grocery shopping choice	Segmentierung von Einkäufern verschiedener Artikel im Supermarkt anhand des Wochentags	Scanner-Panel-Daten	Latente Klassenanalyse	Wochentag	• Abhängig vom Wochentag lassen sich unterschiedliche Kundengruppen unterscheiden, die bestimmte Produkte in Supermärkten einkaufen

Stone et al. (2012)	Day-of-week mood patterns in the United States: On the existence of 'Blue Monday', 'Thank God it's Friday' and weekend effects	Untersuchung des Wochentag-Einflusses auf positive und negative Gefühle	Telefonische Fragebogen-Daten	Regressionanalyse	Wochentag, Werktag vs. Wochenende	- Kunden weisen am Wochenende und an Freitag eine bessere Stimmung auf als unter der Woche - Der Einfluss des Wochentags auf die Stimmung wird unter anderem moderiert von Alter und Familienstatus der Kunden
Zhang et al. (2022)	The situational nature of impulse buying on mobile platforms: a cross-temporal investigation	Untersuchung von Impulskäufen auf mobilen Plattformen abhängig von externen Stimuli	Umfrage-Daten	Partial Least Squares Strukturgleichungsmodell (PLS-SEM)	Ferienzeit vs. außerhalb der Ferienzeit	- Ferienzeit (vs. außerhalb der Ferienzeit) moderiert den Einfluss von Webseite-Stimuli (Qualitätsindikatoren) und Marketing-Stimuli (Preis) auf kognitive und affektive Reaktionen der Kunden - Außerhalb der Ferienzeit achten Kunden eher auf die Qualität der Webseite (im Vergleich zu den Preisen).
Diese Studie	Sunday gleich Friday? Die Analyse und Prognose von Zeiteffekten im Online-Kundenverhalten im Versicherungsbereich mittels Machine Learning	Untersuchung von Zeiteffekten und Vorhersage von Onlineabschlüssen bei einem Versicherungsbereich	Clickstream-Daten	t-Tests, Varianzanalyse (ANOVA), Machine Learning-basierte Zeitreihenmodelle	Wochentag, Werktag vs. Wochenende, Feiertag, Jahreszeit	- Online-Kundenverhalten bei Versicherungen unterliegt wochenend-, feiertags- und jahreszeitspezifischen Effekten - Am Wochenende, an Feiertagen sowie im Frühling und Sommer besuchen weniger Kunden die Webseite und schließen weniger Kunden eine Versicherung online ab - Zeiteffekte sind insbesondere bei der Wahl von stationären Geräten, weniger bei der Wahl mobiler Geräte zu beobachten - Aufbauend auf Zeiteffekte können Verhaltensweise präzise vorausgesagt werden mithilfe Zeitreihenmodelle auf Basis von Machine Learning

Literaturverzeichnis

- Adesso SE (2022): Adesso Digital Commerce Studie 2023. <https://www.adesso.de/adesso-de/downloads/adesso-digitalcommerce-studie-finance.pdf>.
- Ahlbom, C.-P./Roggeveen, A. L./Grewal, D./Nordfält, J. (2023): Understanding How Music Influences Shopping on Weekdays and Weekends. In: *J Mark Res*, 60(5), 987–1007. DOI: 10.1177/00222437221150930.
- Albrecht, T./Rausch, T. M./Derra, N. D. (2021): Call me maybe: Methods and practical implementation of artificial intelligence in call center arrivals' forecasting. In: *J Bus R*, 123, 267–278. DOI: 10.1016/j.jbusres.2020.09.033.
- Barrow, D. K. (2016): Forecasting intraday call arrivals using the seasonal moving average method. In: *J Bus R*, 69(12), 6088–6096. DOI: 10.1016/j.jbusres.2016.06.016.
- Barwitz, N. (2020): The relevance of interaction choice: Customer preferences and willingness to pay. In: *J Retail Consum Serv*, 53, 101953. DOI: 10.1016/j.jretconser.2019.101953.
- Box, G. E. P. (2016): Time series analysis: Forecasting and control. Fifth edition. Hoboken, New Jersey. John Wiley & Sons, Inc (Wiley series in probability and statistics).
- Box, G. E. P./Jenkins, G. M./Reinsel, G. C. (2008): Time series analysis: Forecasting and control. (fourth edition). In: *J Wiley & Sons* (2008). <https://learning.oreilly.com/library/view/-/9780470272848/?ar>.
- Bussière, D. (2011): The Day of the Week Effect in Consumer Behavior: Analyzing Utilitarian and Hedonistic Consumer Modes. In: *J Promot Manag*, 17(4), 418–425. DOI: 10.1080/10496491.2011.620477.
- Canova, L./Nicolini, M. (2019): Online price search across desktop and mobile devices: Evidence on cyberslacking and weather effects. In: *J Retail Consum Serv*, 47, 32–39. DOI: 10.1016/j.jretconser.2018.10.010.
- de Haan, E./Kannan, P. K./Verhoef, P. C./Wiesel, T. (2018): Device Switching in Online Purchasing: Examining the Strategic Contingencies. In: *J Mark*, 82(5), 1–19. DOI: 10.1509/jm.17.0113.
- Holmlund, M./van Vaerenbergh, Y./Ciuchita, R./Ravald, A./Sarantopoulos, P./Ordenes, F. V./Zaki, M. (2020): Customer experience management in the age of big data analytics: A strategic framework. In: *J Bus R*, 116, 356–365. DOI: 10.1016/j.jbusres.2020.01.022.
- Hyndman, R. J./Athanasopoulos, G. (2018): Forecasting: Principles and practice. 2nd print ed. Lexington, Ky. OTexts (2018).
- James, G./Witten, D./Hastie, T./Tibshirani, R. (2021): An introduction to statistical learning: With applications in R. Second edition. New York, NY, U.S.A., Ann Arbor, Michigan. Springer; ProQuest (Springer texts in statistics). <https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=2985424>.
- Klopfer, L.-M./Steul-Fischer, M./Zitzmann, A. (2022): Customer Experience Management – Eine qualitative Studie zur Umsetzung in der Versicherungsbranche. In: *ZVersWiss*, 111(3), 245–276. DOI: 10.1007/s12297-022-00531-6.

- Lazzeri, F. (2021): Machine learning for time series forecasting with Python. Indianapolis, Indiana. Wiley. <https://onlinelibrary.wiley.com/doi/book/10.1002/9781119682394>.
- Lemon, K. N./Verhoef, P. C. (2016): Understanding Customer Experience Throughout the Customer Journey. In: J Mark, 80(6), 69–96. DOI: 10.1509/jm.15.0420.
- Namin, A./Dehdashti, Y. (2019): A „hidden“ side of consumer grocery shopping choice. In: J Retail Consum Serv, 48, 16–27. DOI: 10.1016/j.jretconser.2019.01.009.
- Park, S./Lee, D. (2017): An empirical study on consumer online shopping channel choice behavior in omni-channel environment. In: Telemat Informat, 34(8), 1398–1407. DOI: 10.1016/j.tele.2017.06.003.
- Pedregosa, F./Varoquaux, G./Gramfort, A./Michel, V./Thirion, B./Grisel, O. et al. (2011): Scikit-learn: Machine learning in Python. <https://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf?ref=https://githubhelp.com>.
- Rausch, T. M./Derra, N. D./Wolf, L. (2022): Predicting online shopping cart abandonment with machine learning approaches. In: International Journal of Market Research, 64(1), 89–112. DOI: 10.1177/1470785320972526.
- Stone, A. A./Schneider, S./Harter, J. K. (2012): Day-of-week mood patterns in the United States: On the existence of ‚Blue Monday‘, ‚Thank God it’s Friday‘ and weekend effects. In: The Journal of Positive Psychology, 7(4), 306–314. DOI: 10.1080/17439760.2012.691980.
- Taylor, J. W. (2008): A Comparison of Univariate Time Series Methods for Forecasting Intraday Arrivals at a Call Center. In: Manage Sci, 54(2), 253–265. DOI: 10.1287/mnsc.1070.0786.
- Wolf, L. (2023): Device-mediated customer behavior on the Internet – A systematic literature review. In: Int J Consumer Studies, 47(6), 2270–2304. DOI: 10.1111/ijcs.12925.
- Zhang, L./Shao, Z./Zhang, J./Li, X. (2022): The situational nature of impulse buying on mobile platforms: A cross-temporal investigation. Electronic Commerce Research and Applications, 56, 101204. DOI: 10.1016/j.elerap.2022.101204.