

Marketing Review St.Gallen

Sustainable Consumption

Schwerpunkt

How and When to Communicate
Sustainability – An interview with Mélanie
Brinbaum, Chief Brand Officer at Nespresso

Die grüne Schweizer KonsumentIn

Sustainable Consumption Communities –
Relevance and Acceptance

Bio, vegan – oder was? – Nachhaltiger
«Fleisch»- und «Wurst»-Konsum als Aufgabe der
Kommunikations-, Produkt- und Sortimentspolitik
des Lebensmitteleinzelhandels –
Fallstudie am Beispiel EDEKA Südwest

Perceptions of Sustainability vs. Quality
Features – An Experimental Study on
Young Consumers' Quality Perceptions
of Foods and Beverages

Sind schönere Produkte nachhaltiger? –
Produktdesign-Kriterien für ein suffizientes
Kauf- und Nutzungsverhalten
im B-to-C- und B-to-B-Segment



Spektrum

In-Store-Customer-Analytics –
Messansätze zum besseren Verständnis
des ungenutzten Konversionspotenzials

Sales Transformation –
Quo Vadis, B2B Sales?

In-Store- Customer- Analytics

Messansätze zum besseren
Verständnis des ungenutzten
Konversionspotenzials

Der Aufenthalt im stationären Handel ist häufig kurz, nur Bruchteile des Layouts werden besucht und dies mündet in ungenutztem Konversionspotenzial. Das wachsende Online-Geschäft verschärft den Bedarf nach stationärer Effizienz. In diesem Spannungsfeld systematisiert der Beitrag die Möglichkeiten von In-Store-Customer-Analytics und demonstriert dessen Mehrwert in einem Anwendungsbeispiel.

Prof. Dr. Michael Jungbluth, Dr. Anna Ulrichshofer, Prof. Dr. Christian Schlereth

Der Handelsverband in Deutschland prognostizierte dem Einzelhandel nach der Corona-Pandemie und vor Start der europäischen Energiekrise insgesamt ein Umsatzwachstum (HDE, 2022). Dieses Wachstum wird allerdings hauptsächlich dem Online-Handel zugeschrieben, bei gleichzeitigem Rückgang der Umsätze in stationären Filialen. Rudolph et al. (2021) heben ebenfalls die massive Bedeutungszunahme von Online-Kanälen zwischen 2017 und 2021 hervor. Die Studie zeigt: Neben steigenden reinen Online-Kanal-Transaktionen begünstigen auch Mehrkanal-Entscheidungen zunehmend den Abschluss im Online-Kanal.

Handelsunternehmen müssen sich daher die Frage stellen, ob und wie sich die Bedarfsstruktur ihrer Kundschaft am stationären Point of Sale (sPoS) verändert und ob sich der vergleichbar hohe Kapitalbedarf für solche Touchpoints noch ausreichend rentiert. Dazu gehört ein klares Verständnis, welche Chancen und Risiken aus dem hohen disruptiven Druck auf den sPoS entstehen (Kahn, 2021). Die grossen Plattform-Ökosysteme verschärfen diesen Druck durch Technologieführerschaft: Amazon investiert seit 2015 umfangreich in die Übertragung digitaler Technologien auf den sPoS (Kolf & Kort, 2022). Alibaba verfolgt mit den sogenannten Hema-Stores ähnliche Ziele (Wang & Coe, 2021). Mitte 2022 kündigte Amazon einen Store-Analytics-Service für ihre Amazon-Go- und -Fresh-Ladengeschäfte an (Amazon, 2022). Es handelt sich dabei um eine auf Tracking-Technologie aufbauende Analyse stationären Kaufverhaltens zur Vermarktung an Hersteller. Damit überträgt Amazon grundlegende Web-Analytics-Prinzipien auf den sPoS.

Der vorliegende Beitrag greift diese aktuellen Entwicklungen auf und behandelt die Etablierung von In-Store-Customer-Analytics (ISCA) zur Messung des kundenbezogenen Verhaltens im stationären Handel. Dabei verfolgt der Beitrag drei Ziele: Erstens soll die grundlegende Motivation für

mehr kundenbezogene Verhaltens-transparenz am sPoS abgeleitet werden. Zweitens sollen die technologischen Möglichkeiten und Restriktionen vorhandener Tracking-Technologien und der dadurch entstehenden Datenobjekte für ISCA systematisiert werden. Drittens untermauert der Beitrag den Mehrwert von ISCA beispielhaft durch einen empirischen Anwendungsfall, bei dem der Zusammenhang zwischen Aufenthaltsdauer, Anzahl besuchter Warengruppen und Kaufwahrscheinlichkeit analysiert wird. Die Verfolgung der drei Ziele liefert Entscheidungsträgerinnen und -trägern im Einzelhandel Unterstützung bei Technologieentscheidungen zu ISCA. Zum Abschluss schliesst der Beitrag mit einer Diskussion sowie dem weiteren Forschungsbedarf.

Zur Relevanz eines transparenten sPoS im Mehrkanal-Mix

Die Grenzen zwischen On- und Offline-Kanälen verschwimmen immer



Prof. Dr. Michael Jungbluth
Lehrstuhl für AI in Consumer Commerce
der THI Business School –
Technische Hochschule Ingolstadt
Tel.: +49 (0) 841 9348-3543
michael.jungbluth@thi.de

Dr. Anna Ulrichshofer
Wissenschaftliche Mitarbeiterin
am Lehrstuhl für AI in Consumer Commerce
der THI Business School –
Technische Hochschule Ingolstadt
anna.ulrichshofer@thi.de

Prof. Dr. Christian Schlereth
Lehrstuhl für Digitales Marketing –
WHU Otto Beisheim School of Management
christian.schlereth@whu.edu

mehr durch den Einsatz innovativer Technologien wie Augmented Reality (AR), Internet der Dinge oder Künstliche Intelligenz (Brynjolfsson, 2013; Shankar, 2018). Gleichzeitig herrschen nur noch geringe Wechselkosten für Besucherinnen und Besucher, denn das digitale Kanalangebot des Wettbewerbs ist «nur einen Klick entfernt». Daher steigt für Handelsunternehmen die Bedeutung einer konsistenten, kundenorientierten Verzahnung angebotener Mehrwerte in kanalübergreifenden Customer Journeys (Lemon & Verhoef, 2016). Customer Journeys im Handel umfassen nach wie vor den sPoS als wesentlichen Touchpoint (Herhausen et al., 2019). Pauwels und Neslin (2015) zeigen den positiven Nettoeffekt zusätzlicher stationärer Verfügbarkeit in einem Mehrkanal-Vertrieb. Warby Parker erhöht die Nachfrage und verringert Rücksendungen durch die Eröffnung von Showrooms (Bell et al., 2018). Zhang et al. (2022) zeigen für Produkte mit einer hohen visuellen, haptischen oder explorativen Inspektionstiefe, dass der sPoS den Kundenwert mehr als alle anderen Kanäle erhöht und online Folgekäufe anregt.

Trotz der nachhaltigen Bedeutung des sPoS und der notwendigen Verschmelzung von On- und Offline-Kanälen hat der sPoS einen datengetriebenen Nachteil: Verhaltensmuster von Besucherinnen und Besuchern im Ladengeschäft sind, verglichen mit E-Commerce-Sessions (Web-Analytics), nur zu deutlich höheren Kosten in detaillierte Verhaltensdaten zu überführen. Am sPoS gibt es im Gegensatz zu diskreten Webseitenaufrufen umfangreichere Verhaltensoptionen. Je besser das Handelsunternehmen diese versteht, desto kundenzentrierter kann der sPoS gestaltet werden. Ohne stationäres Tracking messen Drehkreuze den Zufluss von Besucherinnen und Besuchern und Warenkorbdaten das Kaufergebnis. Ein Web-Analytics-Tool, das lediglich die Aufrufe der Startseite und die abgeschlossenen Warenkörbe darstellt, wäre heutzutage für E-Commerce-Verantwortliche undenkbar. Die effektive Verschmelzung von On- und Offline erfordert, dass beide Kanäle stattfindendes Kaufverhalten möglichst unverzerrt erfassen und einer gemeinsamen Analytik zugänglich machen.

Vom transaktionsorientierten Point of Sale zum kundenorientierten Point of Need

Die Aufenthaltsdauer von Besucherinnen und Besuchern im stationären Handel ist unelastisch (Sorensen, 2017) und Online-Kanäle bieten meist umfangreichere Produktinformationen, grössere Sortimente, höhere Transparenz zwischen Anbietern und attraktivere Preise aufgrund geringerer Fixkosten (Reinartz et al., 2019). Technologien haben das Potenzial, diese strukturellen Nachteile des sPoS zu kompensieren. Sie sollten daher so eingesetzt werden, dass Besucherinnen und Besucher neue

Mehrwerte realisieren. Dafür müssen Handelsunternehmen das stationäre Format stärker bedarfsorientiert als Point of Need etablieren. Reinartz und Imschloß (2017) argumentieren, dass eine digitale Augmentierung der klassischen Transaktionsorientierung physischer Ladengeschäfte nicht mehr zielführend ist. Stattdessen steht der Begriff Point of Need sinnbildlich dafür, alle Anforderungen an Digitalisierung und Technologie auf neue bzw. zusätzlich geschaffene Kundenmehrwerte auszurichten.

Der Point of Need unterliegt dabei permanenter Veränderung: Wahrgenommene Mehrwerte, wie z.B. Self-Checkout-Kassen, degradieren über die Zeit von Begeisterungs- zu Basisanforderungen (Berger et al., 1993). Neue Technologien können bewährte Konzepte jederzeit schöpferisch zerstören (Kahn, 2021). Augmented Reality wird z.B. einen grossen Einfluss auf etablierte stationäre Navigations-, Service- und Entertainmentkonzepte haben (Tan et al., 2022).

ISCA hilft Handelsunternehmen bei der kontinuierlichen Bewertung von Effektivität und Effizienz der transformativen Massnahmen hin zum Point of Need. Abbildung 1 visualisiert, wie ISCA durch Messung und Analyse von Verhaltensdaten einen quantitativen Bezug der Wertschöpfungsquellen zu den wahrgenommenen Mehrwerten der Besucherinnen und Besucher herstellen und diesen optimieren kann. Führen z.B. PoS-Informationssysteme zu einer Vereinfachung, die sich in kürzeren Wegstrecken niederschlägt? Welche Effekte sind auf den Warenkorb zu beobachten? Können die Standorte der Informationssysteme optimiert werden? In den digitalen Kanälen werden solche Fragen mittels Web-Analytics und A/B-Tests bereits breit adressiert. Die folgenden Abschnitte vertiefen die Möglichkeiten der Messung, Analyse und Optimierung im Rahmen von ISCA.

Messung durch Observation

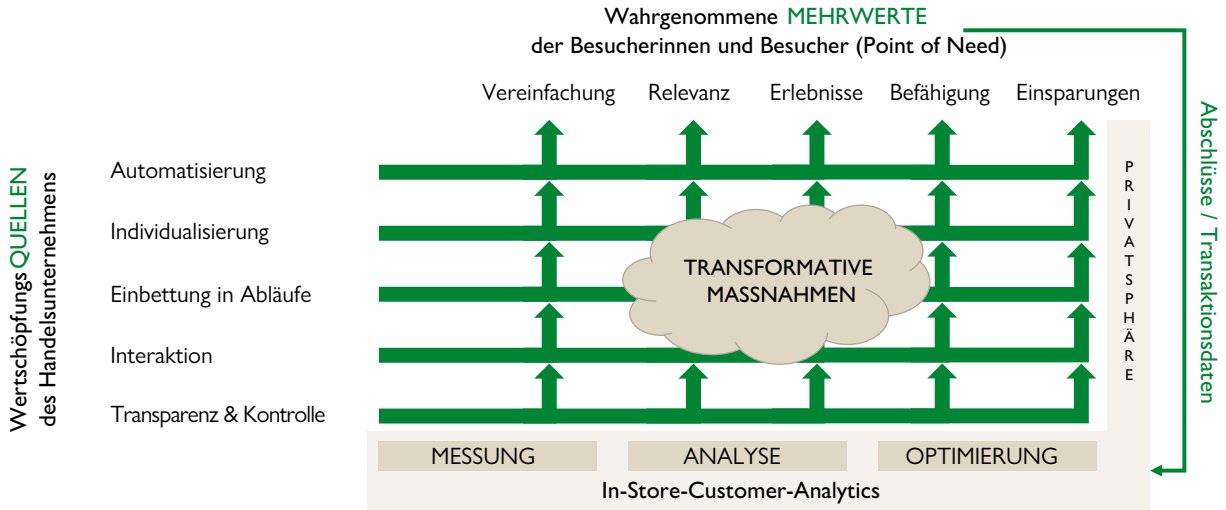
Kaufverhalten am sPoS kann auf vielfältige Arten observiert und damit gemessen werden. Sarantakos (1993) und Kepper (2008) unterscheiden Observationsansätze nach dem Eingriff der Observierenden in die Erhebungsumgebung und wie dieser Eingriff organisiert ist. In Interviews mit vier Handels- und Technologie-Experten wurden praxisrelevante Observationsansätze diskutiert und auf Vollständigkeit im heutigen digitalen Zeitalter geprüft. Zudem erfolgte eine Verortung der identifizierten Ansätze hinsichtlich der damit verbundenen Kosten- und Leistungsaspekte. Abbildung 2 verdichtet die Einschätzung, welche von den Experten im Nachgang der Interviews zur Prüfung auf Diskrepanzen zur eigenen Meinung validiert wurde. Die relevanten Leistungsdimensionen sind:

- Technologische Präzision,
- Schutz der Privatsphäre,
- Skalierbarkeit (im Sinne der erfassten Personengruppe) und
- Repräsentativität (im Sinne einer bewussten vs. unbewussten Teilnahme der Besucherin oder des Besuchers).

Die gegenüberzustellende Kosten-dimension inkludiert neben der initialen Umsetzung des Messansatzes auch wiederkehrende Instandhaltungs- und Erhebungskosten. Kombinierte Messansätze (z.B. mittels Sensor-Fusion) wurden nicht betrachtet.

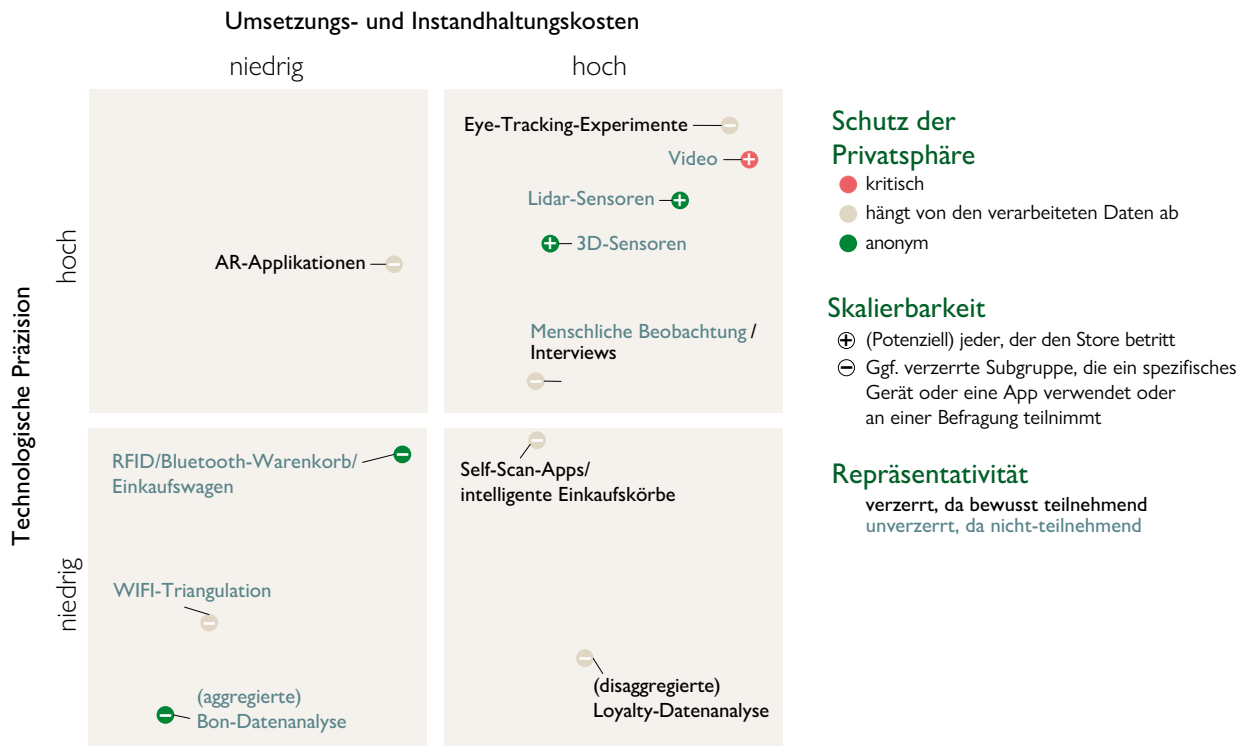
Es herrscht ein heterogenes Bild mit spezifischen Vor- und Nachteilen bei den Observationsansätzen. Die Bon-Datenanalyse und WIFI-Triangulation sind aus einer Gesamtkostensicht günstige, aber unpräzise Varianten. Loyalty-Daten verbessern die Präzision durch Zuordnung von Wiederholungskäufen mit hohen, aber oft bereits versunkenen Programmkosten. Die Präzision einer Triangulation ist meist zu gering, unter-

Abb. 1: Messung, Analyse und Optimierung transformativer Massnahmen



Quelle: Eigene Darstellung in Anlehnung an Reinartz et al., 2019.

Abb. 2: Klassifikation von Messansätzen



Quelle: Eigene Darstellung.

liegt Störeinflüssen und kann je nach Use-Case ein Opt-in erfordern (Liu et al., 2020). Ein RFID/Bluetooth-Einkaufswagen verbessert die Messpräzision. Hier wird allerdings ein Objekt und nicht zwingend das Verhalten der Besucherin oder des Besuchers registriert (Larson et al., 2005). Die Bon-Datenanalyse bezieht sich ausschliesslich auf gekaufte Artikel und blendet daher das Verhalten innerhalb von Nichtkauf-Kategorien und Bewegungssequenzen aus. So bleiben z.B. Erst- und Zweitplatzierungen undifferenziert und es fehlen wichtige Beobachtungen zum Entscheidungsprozess (gesehen > erwogen > gekauft / nicht gekauft).

Self-Scan-Apps, intelligente Einkaufskörbe und AR-Applikationen sind attraktiv, da die Nutzung an konkrete Kundenmehrwerte gekoppelt ist (Hoyer et al., 2020; Tan et al., 2022). Self-Scan-Apps erleichtern den Check-out, liefern mehr Produktinformationen und können sogenannte Shopper-Missionen (z.B. Einkauf nach Rezept) begleiten und vereinfachen. Die Tracking-Funktionalität ist ein «Abfallprodukt» der Nutzung. Im Mittelpunkt steht der konzipierte Applikationsmehrwert, der an der erreichten Umsatzdurchdringung gemessen werden muss (Skalierung).

3D- und Lidar-Sensorik zeichnen sich durch Vorteile der Anonymität und Erfassbarkeit aller Besucherinnen und Besucher aus. Jedoch werden nicht alle Bewegungsströme vollständig erfasst, da die Messungen auf eine kontinuierlich freie Sichtlinie angewiesen sind (Mäkelä et al., 2014). Dennoch stehen unmittelbar ab Projektstart umfangreiche und hoch präzise Lokationsdaten zur Verfügung, da es keiner kundenseitigen Adoption bedarf. Entsprechend verhalten sich Besucherinnen und Besucher natürlich, da sie sich der Beobachtung häufig nicht bewusst sind. Videoaufnahmen können neben Eye-Tracking-Experimenten die umfangreichsten Verhaltensdetails erfassen und mittels Computer-Vision

Zusammenfassung

Ein wachsendes Online-Geschäft und kürzer werdende physische Aufenthalte im stationären Handel erfordern eine konsequente Bedarfs- und Massnahmenorientierung am stationären Point of Sale. In-Store-Customer-Analytics kann auf unterschiedlichen Messansätzen aufbauen, einen quantitativen Massnahmenbezug auf Kundenebene herstellen und diesen optimieren. Die in diesem Beitrag beispielhaft abgeleiteten Bewegungsdaten zeigen signifikante Zusammenhänge mit den erfassten Transaktionen und motivieren die Übertragung von mehr Web-Analytics-Standards auf den stationären Kanal.

extrahieren (z.B. Gestik, Körperhaltung, Interaktion und Stimmung) (Gross, 2019). Dies ist jedoch kostenintensiv und mit hohen Privacy-Herausforderungen verbunden.

Zur nachhaltigen Erreichung der in Abbildung 1 dargestellten Mehrwerte muss ISCA übergeordnete Rechte auf

zuholen. Nicht-teilnehmende Ansätze dürfen keine personenbezogenen Daten verarbeiten oder Rückschlüsse ermöglichen. Andernfalls ist die Einwilligung der Besucherinnen und Besucher vor Betreten der Ladenfläche einzuholen, was nicht praktikabel ist. Methodisch stellt sich zudem die Frage, wie viele sPoS mit Tracking-Technologie auszustatten sind, um im Analyse- und Optimierungsschritt generalisierungsfähige Ergebnisse ableiten zu können. Dies hängt neben der jeweiligen Filial- und Organisationsstruktur des Händlers auch vom Methodeneinsatz ab.

Kundenbezogene Analyse- und Optimierungsschritte

Zentrale neue Datenobjekte von ISCA sind die Besucherinnen und Besucher und der sPoS. Die Messung erfasst für die Besucherinnen und Besucher Lokationsdaten mit Zeitpunktbezug. Damit lassen sich Geschwindigkeit, Wegstrecken, Aufenthaltsweg und Gruppenkontexte ableiten. Das Datenobjekt sPoS beschreibt mit den Dimensionen Layout, Sortiment und Beschilderung das Potenzial für stationäre Impulse. Die erfassten Bewegungsmuster der Besucherinnen

Die effektive Verschmelzung von On- und Offline erfordert, dass beide Kanäle stattfindendes Kaufverhalten möglichst unverzerrt erfassen und einer gemeinsamen Analytik zugänglich machen.

Privatsphäre der Besucherinnen und Besucher respektieren und schützen. Regulatorische Vorgaben zum Schutz personenbezogener Daten sind bei Messung und Weiterverarbeitung der Verhaltensdaten einzuhalten. Die Anbieter teilnehmender Ansätze haben die Möglichkeit, Einwilligung ein-

und Besucher sind wie eine faktische Ausschöpfung des sPoS-Potenzials zu verstehen und damit wesentlich zur Einschätzung stationärer Effizienz.

Erhobene Befragungsdaten aus Interaktionen mit Besucherinnen und Besucher und vorhandene verhaltensbezogene

Daten aus Warenwirtschafts- und Marketingsystemen können durch einen Lokations- und Zeitabgleich mit den Sensor-Daten kombiniert werden (siehe Abbildung 3). Beim Kauf ordnen Warenwirtschaftsdaten den observierten Verhaltensmustern Warenkörbe zu. Erst dies ermöglicht eine ökonomische Analyse und Potenzialabschätzung auf Individualebene. Der Einbezug von Marketingsystemen kontrolliert Kommunikationseinflüsse über den sPoS hinaus. Interaktionen steuern wichtige psychografische Informationen wie Einstellungen, Werte oder Motivationen bei, sind jedoch aufwendig durch Befragung zu erfassen.

Das folgende Beispiel skizziert, wie ISCA grundsätzlich Muster beschreiben, wichtige Zielgrößen prognostizieren und

optimale Handlungsempfehlungen ableiten kann: In Anlehnung an Abbildung 1 ermöglichen Electronic Shelf Labels (ESL) transformative Massnahmen am sPoS. QR-Codes auf den ESLs verschmelzen On- und Offline-Kanal und geben Zugang zu Produktzusatzinformationen (= Interaktion), personalisierten Coupons (= Individualisierung) und Bewertungen (= Transparenz). Dadurch entstehen kundenbezogene Mehrwerte der Vereinfachung, Relevanz und Einsparung.

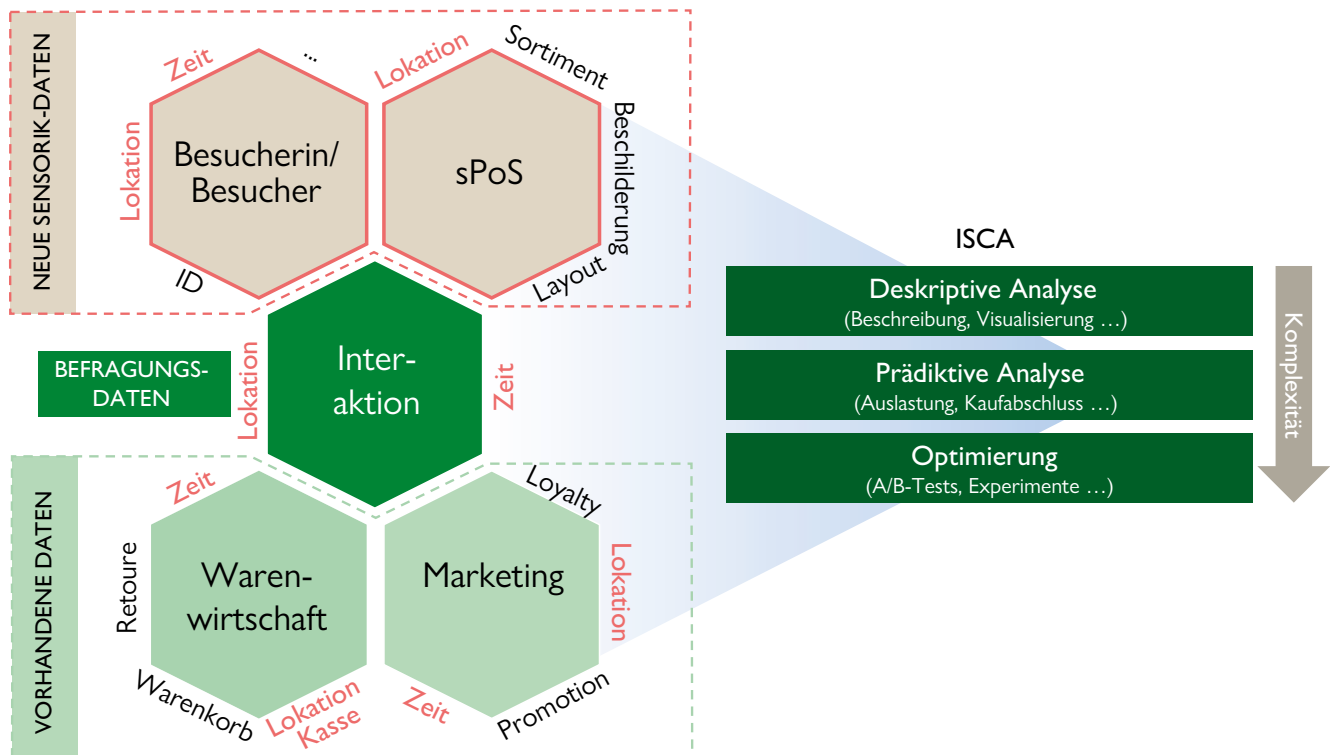
- *Deskriptive Analyse:* Welche Top-Produkte werden an welchem sPoS-Typ von welchen Bewegungsprofilen nicht gesehen, nicht erwogen und/oder nicht gekauft? Bei wie vielen der erwogenen Produkte wurde der QR-Code gescannt? Wie lange dauerte die

Interaktion mit dem QR-Code? Wurden Coupons aktiviert?

- *Prädiktive Analyse:* Können die observierten Verhaltensmuster Kaufentscheidungen prognostizieren? Falls ja, welche Faktoren erhöhen die Kaufwahrscheinlichkeit systematisch? Gehört die ESL-Interaktion dazu?
- *Optimierung:* Separieren gezielte Experimente mit variierender Platzierung und unterschiedlicher Coupongestaltung Preis- und Platzierungseffekte? Welche Gestaltungsoptionen maximieren die Scan-Wahrscheinlichkeit der QR-Codes?

Je mehr Daten erfasst werden und je näher ISCA an konkrete Handlungsempfehlungen geknüpft wird, desto komplexer sind die analytischen Anforderungen.

Abb. 3: Neu entstehende Datenobjekte und -verbindungen für ISCA



Quelle: Eigene Darstellung.

Tabelle 1: Ergebnisse der logistischen Regression

	Kauf					
	(1)	(2)	(3)	(4)	(5)	(6)
Aufenthaltsdauer	0,008*** (0,001)	0,008*** (0,001)	-0,001 (0,001)	-0,003 (0,002)	-0,001 (0,001)	-0,005*** (0,002)
Samstag		0,101*** (0,029)	0,082*** (0,030)	0,001 (0,048)	0,256*** (0,053)	0,167*** (0,056)
Anzahl besuchter Warengruppen			0,100*** (0,008)	0,100*** (0,008)	0,117*** (0,009)	0,127*** (0,009)
Samstag × Aufenthaltsdauer				0,006** (0,003)		0,015*** (0,003)
Samstag × Anz. bes. Warengruppen					-0,058*** (0,015)	-0,097*** (0,017)
Anzahl Observationen	24 381	24 381	24 381	24 381	24 381	24 381
Log Likelihood	-16 607,160	-16 601,240	-16 512,460	-16 510,170	-16 504,500	-16 493,560
Akaike Inf. Crit.	33 218,320	33 208,470	33 032,920	33 030,330	33 019,010	32 999,120

*p<0,1; **p<0,05; ***p<0,01. Quelle: Eigene Darstellung.

Anwendungsbeispiel

Das folgende Beispiel soll den Mehrwert von ISCA demonstrieren. Konkret soll die Kaufentscheidung am sPoS erklärt bzw. diese in Beziehung zur Aufenthaltsdauer, der Anzahl besuchter Warengruppen und dem Wochentag gesetzt werden.

Im Fokus der Analyse steht ein spezialisierter B-to-C-Fachhändler mit über 3000 qm Fläche und 12 Warengruppen. Der sPoS hat für den Fachhändler eine strategische Bedeutung, da dem Grossteil des Sortiments eine hohe visuelle, haptische oder explorative Inspektionstiefe zugeschrieben wird. Die Daten wurden uns freundlicherweise von einem Teststore mit Tracking-Technologie zur Verfügung gestellt. 3D-Sensoren an der Decke erfassen jede halbe Sekunde anonym Lokationen von Besucherinnen und Besuchern.

So wurden für Oktober 2021 24 381 vollständig aufgezeichnete Wegstrecken von Besucherinnen und Besuchern gemessen. Ein Covid-19-Effekt kann aufgrund des

Erhebungszeitraums nicht ausgeschlossen werden. Fast zwei Drittel der Wegstrecken beziehen sich auf weniger als sechs besuchte Warengruppen und eine Aufenthaltsdauer von unter 15 Minuten. Dank des Kassenzzeitstempels lassen sich Wegstrecken konkreten Einkäufen zuordnen. Gemäss Abbildung 3 liegen damit die Datenobjekte der Besucherin oder dem Besucher, sPoS und Warenwirtschaft vor.

Tabelle 1 fasst die Ergebnisse der logistischen Regression zur Überprüfung potenzieller Einflussfaktoren auf observierte Kaufvorgänge zusammen. Hier wurde die Kaufentscheidung (binär) als abhängige Variable mit der Aufenthaltsdauer am sPoS [in Minuten], der Anzahl besuchter Warengruppen [mit Aufenthaltsdauer > 10 Sekunden] unter Kontrolle, ob der Besuch unter der Woche

Kernthesen

- 1 Der hohe disruptive Druck auf den stationären Point of Sale erfordert mehr quantitative Kanal-Transparenz und Bedarfsorientierung.
- 2 Transformative Massnahmen müssen berücksichtigen, dass der stationäre Kundenbedarf stark heterogen und dynamisch ist.
- 3 In-Store-Customer-Analytics ermöglicht umfangreiche Analysen, aufbauend auf einer Vielzahl von Tracking-Möglichkeiten.
- 4 Das Potenzial von In-Store-Customer-Analytics erstreckt sich vom Massnahmen-Controlling über Experimente bis hin zu neuen Geschäftsmodellen.

oder am Samstag stattfand, in Beziehung gesetzt. Weitere Analysedetails sowie ein Test auf Multikollinearität sind im [Online-Anhang](#) berichtet.

Aufenthaltsdauer und Kaufentscheidung stehen unter der Woche in einem signifikant negativen Zusammenhang (Modell (6): $-0,005$; $p < 0,001$). Potenziell vorinformierte und fokussierte Besucherinnen und Besucher mit zeitlichen Restriktionen verbringen wenig Zeit am sPoS. Am Samstag hat hingegen die Aufenthaltsdauer einen positiven Gesamteffekt auf die Kaufentscheidung ($-0,005 + 0,015$; $p < 0,001$), was aus der Summe von Aufenthaltsdauer und dem Interaktionsterm errechenbar ist. Die Anzahl besuchter Warengruppen steht stets im positiven Zusammenhang mit der Kaufentscheidung, sowohl unter der Woche ($0,127$; $p < 0,001$) als auch am Samstag ($0,127 - 0,097$; $p < 0,001$). Eine mögliche Erklärung hierfür liefern Sorensen et al. (2017) und Ghose et al. (2019), welche die Besucherinnen und Besucher am Wochenende als tendenziell inspirationssuchender beschreiben. Sie besuchen viele Warengruppen und haben gleichzeitig eine hohe Aufenthaltsdauer.

Die Ergebnisse unterstreichen somit den Bedarf, auf heterogene, stationäre Einkaufstouren differenziert zu reagieren. Shop-Konzepte sollten tendenziell so aufgebaut werden, dass wochentags dem ersichtlichen Effizienzwunsch der Besucherinnen und Besucher Rechnung getragen wird, ohne dass dies dem höheren Inspirationswunsch am Wochenende entgegensteht. Insbesondere am Wochenende hängt eine längere Aufenthaltsdauer über alle Varianten der Warengruppenabdeckung mit einem deutlichen Anstieg der Kaufwahrscheinlichkeit zusammen. Diese Erkenntnis legt z.B. die Hypothese nahe, Erlebnisorientierung am sPoS fokussiert am Wochenende zu verstärken, um die Verweildauer weiter zu erhöhen.

Handlungsempfehlungen

- 1 Mehrkanal-Handelsunternehmen mit stationärem Kanal sollten Kaufverhalten in allen Kanälen ähnlich gut verstehen, um differenzierende Mehrkanal-Mehrwerte kundenzentriert zu setzen und zu kontrollieren.
- 2 Investitionen in In-Store-Customer-Analytics können durch vielfältige Messansätze an wichtige transformative Massnahmen gekoppelt werden. Damit steht die Erfolgsmessung im Vordergrund und kein komplexes Infrastrukturprojekt.
- 3 Signifikante Zusammenhänge der Messvariablen (z.B. Wegstrecke) mit elementaren ökonomischen Wertgrössen (z.B. Kaufergebnis) sind wichtige Basisvoraussetzungen und entsprechend frühzeitig zu überprüfen.
- 4 In-Store-Customer-Analytics skaliert durch die organisatorische Übertragung der im E-Commerce erprobten Prinzipien von konsequenter Messung, Analyse und iterativer Optimierung.

Diskussion und Forschungsbedarf

Es existieren vielfältige Zugänge zu Verhaltensdaten am sPoS, um transformative Massnahmen vom Point of Sale zum Point of Need effektiv und effizient aufzusetzen. Die entstehenden Daten erfassen je nach verwendeter Technologie komplexe Verhaltensmuster auf Individualebene und weisen für das betrachtete empirische Beispiel signifikante Korrelationsstrukturen mit Kaufentscheidungen auf. Damit kann der ökonomische Wertbeitrag des Point of Need auch konkret bemessen werden.

Am sPoS manifestieren sich formatabhängig unterschiedlichste Verhaltensweisen. Daher variieren die Daten und die damit verbundenen Zusammenhänge mitunter stark. Ausgehend vom dargestellten Anwendungsbeispiel, bestehen folgende Optionen, um die ISCA-Ansätze weiter zu schärfen:

- *Zusätzliche Erklärungsvariablen:* Wichtige Kaufmotivationen und -absichten

sind nur über Befragungen zu erfassen. Welche der vielen bereits fokussierten Besucherinnen und Besucher kaufen trotz Besuch später im Online-Kanal? Welche Motivation liegt dem zugrunde? Sensor-Daten aus nicht-teilnehmenden Beobachtungen beantworten diese wichtigen Fragen isoliert nicht. Regelmässige Befragungen sollten daher kontinuierliche Bewegungsmessungen anreichern.

- *Modellierung nicht-observierbarer Heterogenität:* Die Anwendung fortgeschrittener Modelle aus dem E-Commerce (z.B. Montgomery et al., 2004) verspricht neben einer besseren Modellanpassung an die komplexen Bewegungsdaten auch umfassende Möglichkeiten der Anreicherung mit Befragungsdaten.
- *Fokussierung:* Am sPoS sind nicht alle Elemente kosteneffektiv veränderbar. Daher ist ein Herunterbrechen der Analyse auf veränderbare High-Impact-Bereiche am sPoS (z.B. Optimierung spezifischer Warengruppen) ein naheliegender Ansatz zur Komplexitätsreduktion.

- *Nutzung von ISCA für Experimente:* Zur Bewertung transformativer Massnahmen ist die Gerichtetheit der Effekte von zentraler Bedeutung. Daher ist ISCA auch als Experimentierplattform zu be-greifen. Die erfassten Bewegungsmuster sind wichtige Kontrollinstrumente für Strukturgleichheit. Randomisierte Experimente isolieren gezielt den Wertbeitrag transformativer Massnahmen und sind damit essenziell für die Optimierung. Koning et al. (2022) zeigen, dass gezielte Experimente organisatorisches Lernen von Start-ups verbessern und zu einer höheren Performance führen. Diese Erkenntnis würden viele Händler für den Online-Kanal unterschreiben. ISCA überführt dieses Potenzial auf den sPoS.

All diese Massnahmen erhöhen die Transparenz, was am sPoS passiert und welche Beeinflussungsmöglichkeiten zielgerichtet wirken. Dieses Wissen hat neben der kundenorientierten Optimierung des sPoS auch das Potenzial, neue Geschäftsfelder für den Handel zu eröffnen. Je transparenter der sPoS, desto besser kann dieser Touchpoint vermarktet werden. Brodherson et al. (2022) thematisieren beispielsweise die wachsende Bedeutung von Commerce bzw. Retail-Media. ISCA generiert wertvolle First-Party-Kundendaten der Händler und schliesst den Kreis zwischen Targeting und Transaktion am sPoS.



Weitere ergänzende Tabellen zum Artikel finden Sie unter: unisg.link.mrsg-jungbluth-et-al

Literatur

- Amazon. (2022, 29. Juni). Amazon launches new physical retail store analytics service. <https://www.aboutamazon.com/news/retail/amazon-launches-new-physical-retail-store-analytics-service>
- Bell, D.R., Gallino, S. & Moreno, A. (2018). Offline showrooms in omnichannel retail: Demand and operational benefits. *Management Science*, 64(4), 1629–1651.
- Berger, C., Blauth, R., Boger, D., Bolster, C. Burchill, G., DuMouchel, W., Pouliot, F. Richter, R., Rubinoff, A., Shen, D., Timko, M. & Walden, D. (1993). Kano's methods for understanding customer-defined quality. *Center for Quality Management Journal*, 2(4), 3–35.
- Brodherson, M., Flugstad, J., George, Q., Huang, J. & Trotter, J. (2022, 25. Januar). The rise of commerce media. <https://www.mckinsey.com/business-functions/marketing-and-sales/our-insights/the-rise-of-commerce-media>
- Brynjolfsson, E., Jeffrey Hu, Y. & Rahman, M. S. (2013). Competing in the age of omnichannel retailing. *MIT Sloan Management Review*, 54(4), 23–29.
- Ghose, A., Li, B. & Liu, S. (2019). Mobile targeting using customer trajectory patterns. *Management Science*, 65(11), 4951–5448.
- Gross, R. (2019, 7. Juni). How the Amazon Go Store's AI works. *Towards Data Science*. <https://towardsdatascience.com/how-the-amazon-go-store-works-a-deep-dive-3fde949939e9>
- Handelsverband Deutschland – HDE e.V. & IFH Köln. (2022). *Handelsszenario 2022*. <https://einzelhandel.de/component/attachments/download/10641>
- Herhausen, D., Kleinlercher, K., Verhoef, P.C., Emrich, O. & Rudolph, T. (2019). Loyalty formation for different customer journey segments. *Journal of Retailing*, 95(3), 9–29.
- Hoyer, W.D., Kroschke, M., Schmitt, B., Kraume, K. & Shankar V. (2020). Transforming the customer experience through new technologies. *Journal of Interactive Marketing*, 50(1), 57–71.
- Kahn, B. E. (2021). *The shopping revolution – how retailers succeed in an era of endless disruption accelerated by COVID-19* (2. Aufl.). Wharton School Press.
- Kepper, G. (2008). Methoden der qualitativen Marktforschung. In Herrmann et al. (Hrsg.), *Handbuch Marktforschung: Methoden – Anwendungen – Praxisbeispiele* (3. Aufl., S. 175–212). Gabler.
- Kolf, F. & Kort, K. (2022, 03. März). Amazon schliesst die eigenen Buchläden. *Handelsblatt*. <https://www.handelsblatt.com/unternehmen/handel-konsumgueter/e-commerce-amazon-schliesst-die-eigenen-buchlaeden/28125442.html>
- Koning, R., Hasan, S. & Chatterji, A. (2022). Experimentation and start-up performance: Evidence from A/B testing. *Management Science*, 68(9). <https://doi.org/10.1287/mnsc.2021.4209>
- Larson, J.S., Bradlow, E.T. & Fader, P.S. (2005). An exploratory look at supermarket shopping paths. *International Journal of Research in Marketing*, 22(4), 395–414.
- Lemon, K. N. & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80(6), 69–96.
- Liu, F., Liu, J., Yin, Y., Wang, W., Hu, D., Chen, P. & Niu, Q. (2020). Survey on WIFI-based indoor positioning techniques. *IET Communications*, 14(9), 1372–1383.
- Mäkelä, S. M., Järvinen, S., Keränen, T., Lindholm, M. & Vildjiounaite, E. (2014). Shopper behaviour analysis based on 3D situation awareness information. In C. Distanto, S. Battiato & A. Cavallaro (Hrsg.), *Video analytics for audience measurement, VAAM 2014*. Lecture Notes in Computer Science, 8811, 134–145.
- Montgomery, A. L., Li, S., Srinivasan, K. & Liechty, J. C. (2004). Modeling online browsing and path analysis using clickstream data. *Marketing Science*, 23(4), 579–595.
- Pauwels, K. & Neslin, S.A. (2015). Building with bricks and mortar: The revenue impact of opening physical stores in a multichannel environment. *Journal of Retailing*, 91(2), 182–197.
- Reinartz, W. & Imschloß, M. (2017). From point of sale to point of need: How digital technology is transforming retailing. *GfK Marketing Intelligence Review*, 9(1), 42–47.
- Reinartz, W., Wiegand, N. & Imschloß, M. (2019). The impact of digital transformation on the retailing value chain. *International Journal of Research in Marketing*, 36, 350–366.
- Rudolph T., Kleinlercher, K. & Krall N. (2021). *Omni-Channel Management 2021 in Deutschland, Österreich und der Schweiz*. IRM-HSG. https://handelsverband.swiss/wp-content/uploads/2021/06/OCM-Studie_Handelsverband_swiss.pdf
- Sarantakos, S. (1993). *Social research* (1. Aufl.). Macmillan Education Australia Pty Ltd.
- Shankar, V. (2018). How artificial intelligence (AI) is reshaping retailing. *Journal of Retailing*, 94(4), vi–xi.
- Sorensen, H., Bogomolova, S., Anderson, K., Trinh, G., Sharp, A., Kennedy, R., Page B. & Wright, M. (2017). *Fundamental patterns of in-store shopper behavior*. *Journal of Retailing and Consumer Services*, 37, 182–194.
- Sorensen, H., Heckman, N., Sorensen, J. & Bogomolova, S. (2017). *Inside the mind of the shopper – the science of retailing* (2. Aufl.). Pearson Education.
- Tan, Y. C., Chandukala, S. R. & Reddy, S. K. (2022). Augmented reality in retail and its impact on sales. *Journal of Marketing*, 86(1), 48–66.
- Wang, Y. & Coe, N. M. (2021). Platform ecosystems and digital innovation in food retailing: Exploring the rise of hema in China. *Geoforum*, 126(11.21), 310–321.
- Zhang, J. Z., Chang, C. W. & Neslin, S. A. (2022). How physical stores enhance customer value: The importance of product inspection depth. *Journal of Marketing*, 86(2), 166–185.

Danksagung

Wir danken Olivier Delangre, Nico Hinze, Martin Debus und Arne Meissner für die Bereitschaft, ihre wertvollen Kenntnisse zur Anwendung von In-Store-Analytics in der Praxis mit uns zu teilen.



In-Store-Customer-Analytics

Messansätze zum besseren Verständnis des ungenutzten Konversionspotenzials

Der vorliegende Datensatz besteht aus detaillierten Kunden-Bewegungsdaten eines grossen Handelsunternehmens in der D/A/CH-Region im Oktober 2021. Die Daten werden durch anonymisierte Kassensbon-Daten ergänzt. Insgesamt bestehen die Daten nach Ausreisser-Bereinigung aus 24 381 Einzelkunden, wovon 10 376 einen Kauf tätigen. Es wurden all jene Observationen ausgeschlossen mit Aufenthaltsdauer grösser $75\%Quantil + 3 \times (75\%Quantil - 25\%Quantil)$. Die durchschnittliche Aufenthaltsdauer im Geschäft beträgt 12,83 Minuten, der Median der Anzahl besuchter Warengruppen 2 und 26,2% der Beobachtungen finden an einem Samstag statt. Anhand dieses Datensatzes wurde folgendes Logit-Modell geschätzt¹

$$\begin{aligned}
 \text{Kauf} = & g(\alpha + \beta_1 \text{ Aufenthaltsdauer} + \beta_2 \text{ Samstag} \\
 & + \beta_3 \text{ Anzahl besuchter Warengruppen} \\
 & + \beta_4 \text{ Samstag} \times \text{Aufenthaltsdauer} \\
 & + \beta_5 \text{ Samstag} \times \text{Anzahl besuchter Warengruppen}),
 \end{aligned}$$

wobei $g(z) = \frac{\exp(z)}{1 + \exp(z)}$ die logistische Funktion und die abhängige Variable eine Dummy-Variable mit der Kodierung 1 = Kauf / 0 = Nichtkauf darstellt. Die unabhängige Variable Aufenthaltsdauer gibt die Dauer im Geschäft in Minuten an. Die Variable Samstag ist eine Dummy-Variable mit der Kodierung 1 = Samstag / 0 = Werktag. Die Variable Anzahl besuchter Warengruppen gibt an, wie viele der 12 Warengruppen länger als 10 Sekunden besucht wurden. Die Ergebnisse der Schätzung finden sich in Tabelle 1a. Ein Test auf Multikollinearität ist Tabelle 1b zu entnehmen.

Um sicher zu gehen, dass die Ergebnisse nicht Oktober-spezifisch sind, wurde ein Robustness-Check durchgeführt. Für diesen ist in Tabelle 1c die Schätzung der Regressionsgleichung (1) für den Datensatz, bestehend aus Oktober 2021 und Januar 2022 gegeben, wobei eine Dummy-Variable Januar hinzugefügt wurde, die 1 für Daten aus dem Januar 2022 und 0 für die Oktoberdaten annimmt. ■

Tabelle 1: Logit-Modell zur Kaufentscheidung – (a) Kaufentscheidung

	Kauf					
	(1)	(2)	(3)	(4)	(5)	(6)
Aufenthaltsdauer	0,008*** (0,001)	0,008*** (0,001)	-0,001 (0,001)	-0,003 (0,002)	-0,001 (0,001)	-0,005*** (0,002)
Samstag		0,101*** (0,029)	0,082*** (0,030)	0,001 (0,048)	0,256*** (0,053)	0,167*** (0,056)
Anzahl besuchter Warengruppen			0,100*** (0,008)	0,100*** (0,008)	0,117*** (0,009)	0,127*** (0,009)
Samstag × Aufenthaltsdauer				0,006** (0,003)		0,015*** (0,003)
Samstag × Anz. bes. Warengruppen					-0,058*** (0,015)	-0,097*** (0,017)
Anzahl Observationen	24.381	24.381	24.381	24.381	24.381	24.381
Log Likelihood	-16.607,160	-16.601,240	-16.512,460	-16.510,170	-16.504,500	-16.493,560
Akaike Inf. Crit.	33.218,320	33.208,470	33.032,920	33.030,330	33.019,010	32.999,120

*p<0,1; **p<0,05; ***p<0,01 Quelle: Eigene Darstellung.

(b) Test auf Multikollinearität

	Variance Inflation Factor	Increased Standard Error
Aufenthaltsdauer	1,78	1,33
Samstag	3,60	1,90
Anzahl besuchter Warengruppen	1,81	1,34
Samstag × Aufenthaltsdauer	4,05	2,01
Samstag × Anzahl besuchter Warengruppen	4,85	2,20

Quelle: Eigene Darstellung.

(c) Robustness – Kaufentscheidung mit Januar-Dummy

	Kauf					
	(1)	(2)	(3)	(4)	(5)	(6)
Aufenthaltsdauer	0,009*** (0,001)	0,009*** (0,001)	0,001 (0,001)	0,001 (0,001)	0,001 (0,001)	-0,001 (0,001)
Samstag		0,042* (0,022)	0,028 (0,022)	-0,003 (0,035)	0,158*** (0,039)	0,109*** (0,041)
Januar	0,123*** (0,019)	0,124*** (0,019)	0,120*** (0,019)	0,120*** (0,019)	0,119*** (0,019)	0,119*** (0,019)
Anzahl besuchter Warengruppen			0,084*** (0,005)	0,084*** (0,005)	0,096*** (0,006)	0,101*** (0,006)
Samstag × Aufenthaltsdauer				0,002 (0,002)		0,008*** (0,002)
Samstag × Anz. bes. Warengruppen					-0,043*** (0,011)	-0,064*** (0,012)
Anzahl Observationen	46.288	46.288	46.288	46.288	46.288	46.288
Log Likelihood	-31.687,450	-31.685,580	-31.564,120	-31.563,520	-31.556,030	-31.549,800
Akaike Inf. Crit.	63.380,890	63.379,150	63.138,240	63.139,040	63.124,050	63.113,600

*p<0,1; **p<0,05; ***p<0,01 Quelle: Eigene Darstellung.