
Google Knows it Better?

Ein Plädoyer für integrierte und wider ausschließlich verhaltensorientierte Ansätze zur strategischen Kundensegmentierung

Von Sven Reinecke und Christoph Wortmann

Zusammenfassung

Der vorliegende Beitrag hat sich zum Ziel gesetzt, den aktuellen Hype um „Big Data“ und verhaltensbezogene Daten kritisch zu hinterfragen – insbesondere hinsichtlich der Eignung für langfristige Markt- und Kundensegmentierungen. Dabei soll keinesfalls die Bedeutung dieser neuen Datenquellen geringgeschätzt werden; auch sind Verhaltensdaten für so manche kurzfristige, handlungsorientierte Kundensegmentierung durchaus wertvoll. Für eine langfristige, strategische Segmentierung reichen sie jedoch nicht aus. Dazu ist eine mehrdimensionale, integrierte Kundensegmentierung von Vorteil, die neben Eigenschaften und Verhalten auch Einstellungen und Lebenswelten der Kunden berücksichtigt. Um die hinter dem Kundenverhalten liegenden Motive und Ursachen zu berücksichtigen, liefern die Sinus-Milieus eine wertvolle Basis.

„In God we trust. All others must bring data.“
W. Edwards Deming

1 Big Data im Marketing

Das Datenwachstum ist rasant. Bis 2020 wird sich das weltweite Datenvolumen auf schwer vorstellbare 40 Zettabyte erhöhen (Statista 2017). Getrieben ist diese Entwicklung u. a. durch die Ausbreitung des Internets, den Einsatz mobiler Endgeräte sowie die „Sensorisierung“ im produzierenden Gewerbe (Dorschel 2015). Bei den anfallenden Daten handelt es sich dabei überwiegend um Verhaltensdaten – u. a. generiert aus der Nutzung von Internetseiten, dem Ausfüllen von Online-Bestell-

formularen und Geo-Targeting (Kopp 2014). Diese Datenfülle eröffnet neue Möglichkeiten für die Analyse des Konsumentenverhaltens: Eine Customer Journey muss nicht mehr künstlich in einer Befragungssituation nachgebaut werden, da sie nun real und sogar in Echtzeit beobachtbar ist. Dies bietet zahlreiche Möglichkeiten für ein zielgruppenspezifisches und zeitgerechtes Marketing.

Daher ist es nicht verwunderlich, dass im Zusammenhang mit Big Data eine regelrechte Goldgräberstimmung einsetzt – das Wertschöpfungspotenzial scheint grenzenlos. Allein im Einzelhandelsbereich könne – so die Prognose eines namhaften Beratungshauses – die Gewinnmarge durch den Einsatz von Big Data-Analytics um bis zu 60 % gesteigert werden (Manyika et al. 2011). Diese Erwartungshaltung überträgt sich auch auf das Verhalten der Manager. Eine aktuelle Studie unter Marketingführungskräften zeigt, dass bereits 35 % aller Entscheidungen mit Hilfe von Marketing-Analytics-Tools gefällt werden (The CMO Survey 2016). Aktuelle Forschung weist zudem auf eine Ambivalenz im Stellenwert von „Big Data“ einerseits und klassischer Marktforschung andererseits hin. Top-Entscheider in Marketing und Verkauf schreiben verhaltensbezogenen Daten („Big Data“) eine deutlich höhere Glaubwürdigkeit zu als der klassischen, tendenziell befragungsorientierten Marktforschung und verlassen sich in der Konsequenz mehr auf eben diese Datenquellen (Wortmann et al. 2016). Die Kritik an der klassischen, häufig auf standardisierten Befragungen basierenden Datenerhebung hat zwei Ursachen:

- 1) Häufig sind Kunden nicht willens oder in der Lage, ihr Verhalten zu interpretieren und geben dann sozial erwünschte Antworten, die nicht der Wirklichkeit entsprechen. Das Phänomen der sozialen Erwünschtheit „beschreibt die Tendenz (...) dem zu entsprechen, was der Interviewer oder andere beteiligte Personen vermeintlich von einem erwarten“ (Bogner und Landrock 2015). Darüber hinaus besteht zwischen Kundeneinstellung und -absichten einerseits und dem tatsächlichen Kundenverhalten andererseits häufig ein großer Unterschied. Aus Managementsicht hat daher echtes Verhalten eine viel höhere Glaubwürdigkeit als bekundetes Verhalten.
- 2) Die wahrgenommene methodische Qualität von Befragungen ist stark gesunken, weil Befragungen im Internet scheinbar „günstig“ bzw. „billig“ sind. Die Vielzahl an Online-Befragungen führt ferner dazu, dass die Responsequoten stark fallen („Überbefragung“).

Können verhaltensorientierte Daten und Big Data heute als „heiliger Gral“ in Marketing und Konsumentenforschung angesehen werden? Wird die Datenflut die Welt des Marketings nicht nur transformieren, sondern tatsächlich die Spielregeln radikal ändern? Ohne die Bedeutung und das Potenzial der neuen Daten-

quellen herunterzuspielen, soll im Folgenden kritisch auf eine ausschließlich verhaltensorientierte Erfassung des Konsumenten eingegangen werden.

2 Kritische Thesen zur einseitig verhaltensorientierten Segmentierung

2.1 These 1: Segmentierung ist zielbezogen – somit gibt es unterschiedliche adäquate Ansätze und Methoden.

Kundensegmentierung ist eine Form der Modellierung. Ein Modell ist immer eine vereinfachte Darstellung der Realität, die die für die jeweilige Diskussion besonders relevanten Aspekte hervorhebt. Somit geht es bei einem Modell für anwendungsorientierte Wissenschaften in der Regel weniger darum, ob es richtig oder falsch ist, sondern vielmehr darum, ob es geeignet oder ungeeignet ist.

Für eine Segmentierung von Märkten und Kunden gibt es unterschiedliche Gründe und Anwendungssituationen, beispielsweise:

- Neuproduktentwicklung: Gibt es attraktive Kundengruppen, deren kaufentscheidende Bedürfnisse mit dem bisherigen Leistungsangebot nicht befriedigt werden?
- Marketingkommunikation: Wie lassen sich Kunden hinsichtlich ihrer Medienpräferenzen und ihres Medienkonsums differenziert bearbeiten?
- Buying Center¹: Welche unterschiedlichen Rollen von Kunden sind im Business-to-Business-Geschäft vertreten und bei Marketingmaßnahmen zu berücksichtigen – und welches sind die relevanten Bedürfnisse?
- Online-Segmentierung: Welche Typen von Online-Kunden lassen sich unterscheiden?

Je nach Segmentierungsziel ist es sinnvoll, auf unterschiedliche Segmentierungskriterien zurückzugreifen (Meffert et al. 2015; vergleiche auch den Beitrag von Borgstedt und Stockmann in diesem Band): Denkbar sind u. a. sozio-demografische Kriterien (z. B. Alter, Geschlecht, Einkommen, soziale Schicht), psychographische Merkmale (z. B. Lifestyle, Persönlichkeitsmerkmale, Innovationseinstellungen, aber auch produktbezogene Präferenzen, Einstellungen und Motive), Kundenbedürfnisse (z. B. Bequemlichkeit, Entlastung, Günstigkeit), oder kaufverhaltensbezogene Kriterien (z. B. Erst- oder Wiederkauf, Markenloyalität, Medien-

1 Unter einem Buying Center wird die Gesamtheit aller beim nachfragenden Unternehmen am Beschaffungsprozess involvierten Personen verstanden (Backhaus und Voeth 2011).

nutzung, Onlineverhalten). Welche Kriterien im Einzelfall tatsächlich zum Einsatz kommen, das hängt unter anderem ab von ...

- der Verfügbarkeit der Kundendaten zu angemessenen Kosten in angemessener Zeit und in angemessener Qualität;
- der Trennschärfe der Kriterienausprägungen zwischen den Segmenten und der Homogenität innerhalb der Segmente;
- der Frage, ob die Kundensegmente lediglich beschrieben werden sollen – oder aber ob ihr Verhalten erklärt werden soll;
- der Anzahl der angestrebten Kundensegmente.

Doch wie beurteilt man Kundengruppen, die sich aufgrund einer Segmentierungsstudie ergeben? Freter 2008 und Kotler/Keller 2015 haben diesbezüglich u. a. folgende Anforderungen definiert, die bei der Beurteilung helfen: Erreichbarkeit, Ergiebigkeit und Messbarkeit.

- 1) **Erreichbarkeit:** Unternehmen müssen die entstehenden Kundensegmente auch mit ihren entsprechenden Kommunikations- und Distributionskanälen erreichen können.
- 2) **Ergiebigkeit:** Die Kundengruppen müssen wirtschaftlich tragfähig sein, damit die Profitabilität von Marketingmaßnahmen gewährleistet ist.
- 3) **Messbarkeit:** Die zur Segmentierung eingesetzten Variablen müssen letztlich erfassbar und somit messbar sein.

Je nach Segmentierungsziel sind andere Kriterien und Verfahren der Kundensegmentierung sinnvoll. Verhaltensorientierte Internetdaten (z. B. welchen Browser benutzt der User? Wie ist sein Click-Verhalten?) können für das Online-Marketing äußerst wertvoll sein, weil diese Daten schnell und kostengünstig verfügbar sowie häufig hinreichend differenziert sind, beispielsweise für die Frage, welche weiteren Online-Angebote einem Webseiten-Nutzer gezeigt werden sollten. Der Vorteil der verhaltensorientierten Segmentierung ist der Situationsbezug und somit die Relevanz für das konkrete Kaufverhalten. Für eine integrierte Marketingkommunikation über den gesamten Kaufprozess reicht diese Form der Segmentierung aber häufig nicht aus, weil die Datenverfügbarkeit begrenzt ist oder sich die Datenquellen (z. B. Kundenbestelldaten und Social Media-Nutzung) nicht immer kombinieren lassen.

2.2 These 2: Verhaltensbezogene Daten sind nicht per se „überlegen“. Sie ermöglichen die Beobachtung des Kundenverhaltens – nicht mehr und nicht weniger!

Grundsätzlich ist das Wertschöpfungspotenzial von Big Data und insbesondere verhaltensbezogenen Daten sehr groß (Wedel und Kannan 2016). Beispielsweise konnten McAfee und Brynjolfsson 2012 zeigen, dass datengetriebene Unternehmen (hierbei ging es bewusst nicht um Einstellungsvariablen) im Schnitt 5 % produktiver und 6 % profitabler sind als nicht-datengetriebene Organisationen. Und auch in der Wissenschaft gibt es eindrucksvolle Beispiele: So belegen Trusov et al. 2016 anschaulich, dass das Surfverhalten im Internet (basierend auf Cookies) eine spezifischere Zielgruppenansprache ermöglicht. Die Bedeutung von Verhaltensdaten ist somit unbestritten.

Zu einer ausgewogenen Diskussion gehört aber auch die Berücksichtigung von Grenzen und Schwächen. Ein anschauliches Beispiel hierfür bietet „Google Flu Trends“: Hierbei wurde suggeriert, dass man die Ausbrüche der saisonalen Grippe alleine aufgrund der Häufigkeit, mit der Nutzer Wörter wie „Grippe“, „Husten“ und „Influenza“ in Google Search eintippen, vorhersagen könne. Nach anfänglichen großen Erfolgen scheiterte man kurze Zeit später. In den Jahren 2011/2012 und 2012/2013 wurde das Ausmaß der Ausbrüche um mehr als 50 % überschätzt (Weber 2014; Müller-Jung 2014).

Warum hielt der Prognoseerfolg nicht an? Die Antwort ist relativ einfach: Der entfachte Medienhype um „Google Flu Trends“ hatte dazu geführt, dass auch Personen, welche nicht von Grippesymptomen betroffen waren, nach den entsprechenden Begriffen suchten. Die dahinterliegenden Algorithmen konnten diesen Effekt jedoch nicht herausrechnen, so dass es zu einer deutlichen Überschätzung der Grippewellenausdehnungen kam. Die Daten beruhten zwar auf Kundenverhalten (Eingabe von Suchanfragen), doch stellte sich der vermutete Ursache-Wirkungszusammenhang (Feststellen von Grippesymptomen – Google Suche) als Scheinkorrelation heraus.

Eine weitere Schwachstelle verhaltensgetriebener Datenanalytik offenbart sich bei der Analyse von Kundenkommentaren und -rezensionen in Sozialen Medien und Onlineforen (beispielsweise Facebook, Instagramm, TripAdvisor, Holiday-Check, Amazon). Trotz der vielen durchaus hilfreichen Bewertungen scheitern viele Text Mining-Analysetools (noch) an der korrekten Interpretation von Ironie und Humor (Lemke und Wiedemann 2016). Ein Kommentar (= Nutzerverhalten) kann somit nur im Gesamtzusammenhang korrekt interpretiert werden. Ein und dieselbe Aussage kann unterschiedliche Intentionen haben, die sich nicht allein aus dem Verhalten erschließen. Ein Albert Einstein zugeschriebenes Zitat bringt dies treffend auf den Punkt: „Es gibt keine Daten ohne eine Theorie.“

Dennoch: Diese Unzulänglichkeiten sollten nicht dazu führen, dass man sophisticatede Modelle und Algorithmen grundsätzlich ablehnt, wie dies beispielsweise die Mathematikerin Cathy O’Neil 2016 in ihrem Buch „Weapons of Math Destruction“ fordert. Für die Wirtschafts- und Sozialwissenschaften lässt sich jedoch Folgendes feststellen: Mit Hilfe der Analyse des Surf-, Such- und Klickverhaltens von Kunden im Internet wird das „digitale Verhalten“ lediglich beobachtet. Die dahinterliegenden Gründe und Wechselbeziehungen einer entsprechenden Handlung lassen sich damit aber nicht herausfinden. Diese Nachteile von Beobachtungstechniken sind in der empirischen Sozialforschung ausführlich beschrieben (Diekmann 1995; Kuss et al. 2014). Eine konsequente Übertragung dieser Herausforderung in die digitale Welt findet man aber bislang selten.

Schlägt man nun die Brücke zu Markt- und Kundensegmentierungen, wird die Eindimensionalität von Verhaltensdaten schnell sichtbar. Durch die Fokussierung auf das Nutzungs- und Bestellverhalten im Internet werden wichtige Aspekte einer erfolgreichen Markt- und Kundensegmentierung vernachlässigt, wie beispielsweise psychologische (z. B. Einstellungen) und soziologische Kriterien (z. B. Kultur und Schicht). Verhaltensdaten fallen eher unter die Kriterien des *beobachtbaren Konsumentenverhaltens* (Freter 2008). Sie zeichnen sich durch eine gute Mess- und Operationalisierbarkeit aus (z. B. mittels Clickstream- und Protokolldaten im Internet). Auch sind sie durchaus wirtschaftlich messbar, weil reale Kaufhandlungen beobachtet werden und sowohl Datenerhebung als auch -analyse weitgehend automatisierbar sind. Allerdings werden spezifische Bestimmungsgründe für handlungsauslösende Aktionen nicht erklärt. Zudem werden allenfalls unscharfe Anhaltspunkte geliefert, wie Konsumenten erreicht werden können und wie die Marketinginstrumente segmentspezifisch auszurichten sind (Medelnik 2012). Die Trennschärfe ist gering, auch wenn die Segmentierungsgeschwindigkeit durchaus hoch ist. So wäre es kaum zielführend, sehr heterogene Altersgruppen nur aufgrund ihres Clickverhaltens identisch zu bearbeiten (über Social Media Kanäle), weil sich die jeweiligen Bedürfnisse, Einstellungen, Absichten und Lebenswelten unter Umständen fundamental unterscheiden können. Bereits seit längerem ist bekannt, dass eine ausschließlich auf dem Online-Kaufverhalten basierende Segmentierung dazu führt, dass Kunden eines Unternehmens aus sehr unterschiedlichen Alterskategorien (z. B. „Top Ager“ und „Millenials“) denselben Segmenten zugeordnet werden (Bensberg 2002). Ein solches Vorgehen berücksichtigt weder die Bedürfnisstrukturen noch die Einstellungen noch die Lebenswelten der Kunden. Eine Segmentierung, die eine Kundenansprache im Sinne eines idealtypischen One-to-One-Marketings ermöglicht, erfordert daher die Integration weiterer Variablen, also nicht nur des Kundenverhaltens.

2.3 These 3: Validität und Reliabilität verhaltensbezogener Internetdaten sind begrenzt.

Wird das Onlineverhalten als Grundlage der Kundensegmentierung verwendet, so muss man sich bewusst sein, dass sowohl die Validität als auch die Reliabilität der Datengrundlage begrenzt sind. Exemplarisch sei dies an folgenden Situationen aufgezeigt:

- Cookies werden gelöscht, womit sich das individuelle Surfverhalten nicht mehr zurückverfolgen lässt;
- Benutzer filtern ihre Daten bewusst (und entscheiden beispielsweise, wann sie ins System oder bei Google eingeloggt sind – und wann nicht);
- Personen benutzen unterschiedliche Domains (z. B. zu Hause und im Büro) oder unterschiedliche Geräte („Devices“) und können somit nicht als eine Person identifiziert werden;
- mehrere Personen nutzen denselben Account (z. B. dieselbe Apple ID oder dasselbe Kundenkonto bei Amazon) – und werden somit irrtümlicherweise als derselbe Nutzer identifiziert;
- ein Kundenverhalten wird online ausgelöst (beispielsweise über eine Werbe-E-Mail), aber offline abgeschlossen (z. B. Kauf im Geschäft) – oder umgekehrt;
- der Zeitraum zwischen Marketingmaßnahme (Werbebanner) und Kundenverhalten (Kauf) wird nicht gemessen, sondern die Zurechnung („Attribution“) erfolgt willkürlich.

Ein weiterer gravierender Nachteil verhaltensbasierter Daten im Internet besteht aus Marketingsicht darin, dass die meisten Daten nicht frei verfügbar sind, sondern insbesondere bei zwei „Gatekeeper“-Unternehmen anfallen (Google und Facebook). Dies schränkt sowohl die Effizienz (Nutzen-Kosten-Verhältnis) als auch die Effektivität (z. B. Datenzugang) dieser Segmentierung ein.

2.4 These 4: Die intensive Verwendung verhaltensbasierter Kundendaten führt zu Kundenreaktanz.

So manche Marketing-Führungskräfte versprechen sich von der Verwendung verhaltensorientierter Daten die Möglichkeit, das „Gießkannen-Prinzip“ zu überwinden, hin zum hoch-personalisierten „One-to-One Marketing“: E-Mail-Newsletter werden immer personalisierter und die „Recommender Systems“ im eCommerce haben ihre Kinderkrankheiten überwunden. Dennoch lohnt sich ein kritischer Blick auf diese Form der Personalisierung, denn es besteht die Gefahr, dass eine

hochindividualisierte Kundenansprache auch Reaktanzen erzeugen kann. Gerade wenn der Endverbraucher das Gefühl hat, dass Unternehmen mit den persönlichen und (teilweise) auch sensiblen Daten nicht verantwortungsbewusst umgehen, kann es zu Bumerang-Effekten kommen. Beispielsweise kann sich auf Kundenseite ein Gefühl des „Überwachtwerdens“ ergeben – ein Zustand, der unter allen Umständen vermieden werden sollte, da dies letztlich die Abwanderungsquote determiniert (Tucker 2014). Darüber hinaus sind sich viele Konsumenten überhaupt nicht bewusst, wie Unternehmen an ihre Daten gelangen können. In diesem Zusammenhang ist vollkommene Transparenz entscheidend, um Reaktanz und Abwanderungstendenzen zu vermeiden. Die Firma Uber bietet hierzu ein gutes Anschauungsbeispiel: Der Fahrdienstleistungsvermittler hat sehr intensiv am Thema Datenschutz gearbeitet. Das Unternehmen hat veranlasst, dass Drittpersonen zum Abrufen von Kundendaten Berechtigungen oder gerichtliche Anordnungen vorweisen müssen. Zusätzlich bietet Uber seinen Kunden einen Transparenzbericht und verspricht ihnen, wenn möglich mitzuteilen, falls Gesetzeshüter das Bereitstellen ihrer persönlichen Daten angefordert haben. Nach der in der Vergangenheit oftmals öffentlich bekundeten Sorge des Datenmissbrauchs hat Uber den Wunsch seiner Kunden nach Datenschutz und Transparenz erkannt und umgesetzt (Meola 2016).

2.5 These 5: Eine strategische, integrierte Markt- & Kundensegmentierung erfordert eine Verbindung zahlreicher Kunden- und Verhaltensdaten, Lebensstil- und Einstellungsvariablen aus unterschiedlichen Quellen.


Big Data und verhaltenswissenschaftliche Datenanalyse eignen sich besonders zur Identifizierung von Regelmäßigkeiten und bestimmten Strukturen (Buhl et al. 2013). Das „Warum?“ einer Handlung kann damit aber nicht erklärt werden. Hier bieten sich insbesondere die qualitative Marktforschung (Tiefeninterviews, Expertengespräche, Fokusgruppen), standardisierte Befragungen sowie die Milieuforschung an.

Nicht erst seit der „Theory of Planned Behavior“ von Icek Ajzen 1991 ist bekannt, dass Einstellungen und Normen wichtige Determinanten für das menschliche Verhalten sind. Für eine strategische Markt- und Kundensegmentierung sind daher in der Regel soziologische und psychographische Kriterien zu berücksichtigen, weil andernfalls das Ziel eines differenzierten Marketings kaum zu erreichen ist.

Zur Verdeutlichung der Argumentation sei auf klassische Werbewirkungsmodelle verwiesen. Während die klassische Stimulus-Response (S-R) Theorie

einer Black-Box-Betrachtung gleicht, geht das Stimulus-Organism-Response-Modell (S-O-R-Modell) einen Schritt weiter und integriert nicht nur beobachtbare Variablen (wie beispielsweise Verhaltensdaten), sondern auch entsprechende intervenierende Größen, beispielsweise Einstellungen (Foscht und Swoboda 2011). Häufig sind es insbesondere diese intervenierenden und nicht beobachtbaren Variablen, die das konkrete Konsumentenverhalten erklären. Die Analyse von Einstellungen und Werten ist hier unerlässlich. Bezieht man nun die Milieuforschung, beispielsweise den Ansatz der Sinus-Milieus ein, so ergibt sich noch eine weitere Ebene (vgl. Abbildung 1). Die sozio-kulturellen Lebenswelten, die ebenfalls nicht direkt beobachtbar sind, beeinflussen psychologische Prozesse der (potenziellen) Kunden und prägen somit direkt deren Einstellungen. Nehmen wir beispielsweise die Milieu-Zielgruppe der Performer: Das hier jeweils vorherrschende Umfeld (ähnliche soziale Kontakte, ähnliches räumliches Umfeld usw.) steht in einer direkten Wechselbeziehung zur Entwicklung von Fähigkeiten, Werten und Einstellungen, wie z.B. Multioptionalität, Leistungsorientierung, hohe IT- und Multi-Mediakompetenz, global-ökonomisches Denken.

Abb. 1 Darstellung des S-O-R-Modells, erweitert um die Perspektive der Lebenswelten



© Sven Reinecke & Christoph Wortmann


Möchte man nun die Gründe für einen Kauf dieser Performer-Zielgruppe genauer evaluieren, reicht eine reine Beobachtung bspw. des Kaufverhaltens im Internet nicht aus. Für eine wirksame Kundensegmentierung ist es erforderlich, unterschiedliche Datenquellen miteinander zu kombinieren. An Datenquellen mangelt es im Big Data-Zeitalter zwar nicht, dennoch offenbaren sich in der Praxis häufig Herausforderungen bei der Integration sogenannter „Datensilos“. Verschiedene wissenschaftliche Studien konnten bereits das Wertschöpfungspotenzial einer Da-

tenintegration zeigen. Mit Hilfe eines Praxisbeispiels aus der Finanzwirtschaft belegt Liehr 2001, dass die Verknüpfung interner Kundendaten (CRM) und externer Marktforschungsdaten zu besseren Analysemodellen hinsichtlich der Priorisierung von Kunden führt, so dass ihre unternehmensseitige Betreuung besser und effizienter ausgestaltet werden kann. Dies dient langfristig dem Ziel einer Steigerung des „Share of Wallet“. Weitere praktische Anwendungsbeispiele liefern van Hattum und Hoijtink 2008 und 2009 sowie McDonnell Feit et al. 2013: So kann die Zusammenführung von einstellungs- und verhaltensorientierten Daten der Mediennutzung zu besseren unternehmensweiten Entscheidungen in der Mediaplanung führen, weil etwaige Kannibalisierungstendenzen zwischen den unterschiedlichen Medienplattformen vermieden werden können.

Geht man noch einen Schritt weiter und integriert Lebensstil- bzw. Milieudaten, welche beispielsweise vom SINUS-Institut erhoben und geliefert werden, ergeben sich noch spezifischere Möglichkeiten der Kundensegmentierung und schließlich der Kundeninteraktion. Generelle Wertvorstellungen und Informationen bezüglich der individuellen sozialen Lage werden selten von unternehmensinternen Marktforschungsstudien abgedeckt. Zudem werden die entsprechenden SINUS-Milieustudien regelmäßig angepasst und aktualisiert, so dass auch auf externe Einflüsse reagiert werden kann (Helmke et al. 2016).

Abbildung 2 versucht, die notwendigen Schritte einer erfolgreichen Datenintegration konzeptionell zusammenzufassen. Dabei lassen sich die relevanten Datenquellen grob in drei Cluster einteilen: Daten aus dem Geschäftsbetrieb (z. B. Kontakt- und Transaktionsdaten), Daten aus dem Unternehmen/Markt (z. B. CRM-Daten, Marktforschungsdaten) und sonstige Datenquellen (z. B. Sensordaten und Social-Media-Daten). Es wird deutlich, dass Unternehmen häufig mit sehr heterogenen Datentypen arbeiten müssen – und zwar sowohl mit Verhaltens- als auch Einstellungsdaten (ausführlich Wimmer und Göb 2006 zu Fusionsvorgang, Algorithmen und Heuristiken).

Eine solche Datenintegration ermöglicht ein weitgehendes „360-Grad Bild des Kunden“ (Tomczak und Cristofolini 2002, S. 74). Dieses ist Voraussetzung für eine langfristig erfolgreiche Kunden- und Marktsegmentierung. Zusammengefasst bedeutet das: Eine Integration von Kunden-, Verhaltens- und Lebensstildaten ist eine wertvolle Basis für Marketingplanung und Kundenbearbeitung. Dies soll anhand eines Beispiels im nächsten Abschnitt gezeigt werden.

Abb. 2 Schritte der Datenintegration zur Erlangung eines tieferen Kundenwissens

© Sven Reinecke & Christoph Wortmann, in Anlehnung an Wimmer und Göb 2006 (Abkürzung ind. = individuell)


3 Integrierte Kundensegmentierung mit Hilfe von Sinus-Milieus®

Der Nutzen eines integrativen Ansatzes zur optimalen Kundenansprache (vgl. These 5) konnte bereits durch Praxisbeispiele belegt werden. In diesem Zusammenhang können beispielsweise die DIVSI Internet Milieus genannt werden – hierbei ging es darum, die Gesamtstruktur der digitalen Gesellschaft in Deutschland abzubilden. Dazu hat man sich eines breiten Instrumentariums bedient: Einstellungsvariablen (Motivationen), Lebensweltvariablen (Sinus-Milieus) und berichtetes Nutzungsverhalten im Internet wurden kombiniert, um eine multiperspekti-

vische Sicht auf die digitale Grundhaltung in Deutschland zu ermöglichen (siehe den Beitrag von Borgstedt und Stockmann in diesem Band). Sicherlich muss man relativierend anmerken, dass hier lediglich das berichtete Nutzungsverhalten und nicht das tatsächliche Nutzungsverhalten (über Beobachtung, Tracking etc.) integriert wurde, aber dennoch zeigt der oben genannte Ansatz das inhärente Wertschöpfungspotenzial. Möchten Unternehmen dieses Schema übernehmen, müssen zwingend noch die eigenen Kundendaten mitintegriert werden – ansonsten segmentiert man an der Realität vorbei.

Einen Schritt weiter geht die Angebotsstrukturierung und Kommunikationsplanung von tirol.at, denn in diesem Zusammenhang werden tatsächlich live erhobene Verhaltensdaten (u. a. Tracking des Surfverhaltens auf der Homepage tirol.at) mit Einstellungen via Sinus-Milieus kombiniert. Mithilfe der Lebensweltdaten wird der Mensch hinter dem User identifiziert, und reale Lebenswelten können dem entsprechenden Surfverhalten zugeordnet werden. Dies ergibt die Möglichkeit einer zielgenauen User-Ansprache zur Optimierung wichtiger Kennzahlen. (Vergleiche auch den Beitrag von Hecht und Hribernik in diesem Band.) Abbildung 3 fasst dieses Modell schematisch zusammen.

Abb. 3 Schematische Darstellung des Kollaborationsmodells zur optimalen Zielgruppenadressierung bei tirol.at



4 Fazit: Implikationen für die optimale Nutzung von Verhaltens-, Einstellungs- und Milieudaten

Der vorliegende Beitrag hat versucht, die derzeit stark dominierende Ausrichtung auf Verhaltensdaten in der empirischen Sozialforschung am Beispiel von Markt- und Kundensegmentierungen kritisch zu hinterfragen. Wichtig ist dabei zu betonen, dass die Bedeutung eben dieser Daten keinesfalls negiert werden sollte. Im Gegenteil: Durch den zu erwartenden weiteren technischen Fortschritt in den nächsten Jahren werden Verhaltensdaten noch genauere Beobachtungsvorgänge auf den Kunden ermöglichen und somit weiter an Bedeutung gewinnen. Daraus folgt in der Konsequenz jedoch nicht, dass die „ungeliebte traditionelle Marktforschung“ abgeschafft und teure Studien über die Einstellungen und Lebenswelten von Kunden vermieden werden sollten, denn gerade diese Datentypen sind von hoher Relevanz für eine erfolgreiche Kundensegmentierung. So können Verhaltensdaten das „Warum?“ von gefundenen Zusammenhängen (z. B. das Kaufverhalten im Internet) nicht erklären, was zu einer ungeeigneten Kundenansprache führen kann. Im Beitrag wird ein konkretes Lösungsszenario hinsichtlich einer effizienten und effektiven Kundensegmentierung aufgezeigt: die Datenintegration. Nur eine konsequente Integration möglichst vieler relevanter Datenquellen erlaubt es, den Kunden und sein Verhalten in seinem sozialen Umfeld zu verstehen und mit Marketingmaßnahmen zu bearbeiten.

Google allein weiß somit nicht automatisch alles besser: In Anlehnung an den bekannten Slogan des SINUS-Instituts kann formuliert werden: „Nur wer versteht, was die Kunden bewegt und wie sie sich bewegen, kann sie auch bewegen.“

Literaturverzeichnis

- Adsquare. 2017. Microm And adsquare In Strategic Partnership To Enable Sinus-Milieus® Use For Mobile Marketing. <http://www.adsquare.com/microm-and-adsquare-in-strategic-partnership-to-enable-sinus-milieus-use-for-mobile-marketing/>; Zugriffen: 30. März 2017.
- Ajzen, I. 1991. The theory of planned behavior. *Organizational Behavior and Human Decision Processes* 50: 179–211.
- Backhaus, K. und M. Voeth. 2011. Industriegütermarketing. München: Vahlen.
- Bensberg, F. 2002. CRM und Data Mining. In *Customer Relationship Management im Handel – Strategien, Konzepte, Erfahrungen*. Hrsg. D. Ahlert, J. Becker, R. Knackstedt und M. Wunderlich, 201–226. Berlin: Springer.
- Bogner, K. und U. Landrock. 2015. Antworttendenzen in standardisierten Umfragen. Mannheim, GESIS – Leibniz Institut für Sozialwissenschaften (SDM Survey Guidelines).

- Buhl, H. U., Röglinger, M., Moser, F. und J. Heidemann. 2013. Big Data. Ein (ir-)relevanter Modebegriff für Wissenschaft und Praxis? *Wirtschaftsinformatik* 55: 63–68.
- Diekmann, A. 1995. Empirische Sozialforschung. Grundlagen – Methoden – Anwendungen. Hamburg: Rowohlt.
- Dorschel, Joachim, Hrsg. 2015. Praxishandbuch Big Data. Wirtschaft – Recht – Technik. Wiesbaden: Springer Gabler.
- Glöckner, A., Balderjahn, I. und Peyer, M. 2010. Die LOHAS im Kontext der Sinus-Milieus. *Marketing Review St. Gallen* 27: 36–41.
- Foscht, Thomas, und B. Swoboda. 2011. Käuferverhalten. Grundlagen – Perspektiven – Anwendungen. Wiesbaden: Gabler.
- Freter, Hermann. 2008. Markt- und Kundensegmentierung: kundenorientierte Markterfassung und -bearbeitung. Stuttgart: Kohlhammer.
- Helmke, S., Scherberich, J. U. und Uebel, M. 2016. LOHAS-Marketing. Strategie – Instrumente – Praxisbeispiele. Wiesbaden: Springer.
- Kopp, Gisela. 2014. Behavioral Targeting: Identifizierung verhaltensorientierter Zielgruppen im Rahmen der Online-Werbung. Hamburg: disserta Verlag.
- Kotler, P. und K. L. Keller. 2015. Marketing-Management. Global Edition. Upper Saddle River (NJ): Prentice-Hall.
- Kuss, A., Wildner, R. und Kreis, H. 2014: Marktforschung: Grundlagen der Datenerhebung und Datenanalyse, 5. Auflage. Wiesbaden: Gabler.
- Lemke, M. und G. Wiedemann, Hrsg. 2016. Text Mining in den Sozialwissenschaften. Grundlagen und Anwendungen zwischen qualitativer und quantitativer Diskursanalyse. Wiesbaden: Springer.
- Liehr, T. 2001. „Data Matching“ bei Finanzdienstleistungen: Steigerung des Share of Wallet bei Top-Kunden. In *Handbuch Data Mining im Marketing. Knowledge Discovery in Marketing Databases*, Hrsg. H. Hippner, U. Küsters, M. Meyer und K. Wilde, 725–740. Braunschweig: Vieweg.
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., und C. Roxburgh. 2011. Big data: The next frontier for innovation, competition, and productivity. McKinsey Global Institute. http://www.mckinsey.com/insights/business_technology/big_data_the_next_frontier_for_innovation; Zugriffen: 20. März 2017.
- McAfee, A. und E. Brynjolfsson. 2012. Big Data: The Management Revolution. *Harvard Business Review* 90: 3–9.
- McDonnell Feit, E., Wang, P., Bradlow, E. T. und Fader, P. S. 2013. Fusing Aggregate and Disaggregate Data with an Application to Multiplatform Media Consumption. *Journal of Marketing Research* 50: 348–364.
- Medelnik, N. G. 2012. Wert- und bedürfnisorientierte Segmentierung von Konsumgütermärkten. Wiesbaden: Gabler.
- Meffert, H., Burmann, C., und M. Kirchgeorg. 2015. Marketing – Grundlagen marktorientierter Unternehmensführung Konzepte – Instrumente – Praxisbeispiele. Wiesbaden: Gabler.
- Meola, A. 2016. Two surprising companies lead the pack in user data privacy and transparency. <http://www.businessinsider.com/uber-leads-in-user-privacy-and-data-transparency-2016-5>; Zugriffen: 05. Mai 2017.

- Müller-Jung, J. 2014. Schmutzige Daten. <http://www.faz.net/aktuell/wissen/medizin-ernaehrung/grippe-prognosen-mit-google-schmutzige-daten-12851452.html>; Zugriffen: 30. März 2017.
- O'Neil, C. 2016. *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*. New York: Crown.
- Statista. 2017. Prognose zum Volumen der jährlich generierten digitalen Datenmenge weltweit in den Jahren 2005 bis 2020 (in Exabyte). <https://de.statista.com/statistik/daten/studie/267974/umfrage/prognose-zum-weltweit-generierten-datenvolumen/>; Zugriffen: 27. März 2017.
- The CMO Survey. 2016. CMO Survey Report: Highlights and Insights. https://cmosurvey.org/wp-content/uploads/sites/11/2016/02/The_CMO_Survey-Highlights_and_Insights-Feb-2016.pdf; Zugriffen: 1. April 2017.
- Tomczak, T. und M. Cristofolini. 2002. Customer Intelligence – oder: Wie lerne ich meine Kunden besser kennen? *persönlich – Die Zeitschrift für Marketing und Unternehmensführung* 11: 74–75.
- Trusov, M., Ma, L. und Z. Jamal. 2016. Crumbs of the Cookie: User Profiling in Customer-Base Analysis and Behavioral Targeting. *Marketing Science* 35: 405–426.
- Tucker, C. 2014. Social Networks, Personalized Advertising and Privacy Controls. *Journal of Marketing Research* October 2014: 546–562.
- van Hattum, P. und H. Hoijsink. 2008. The proof of the pudding is in the eating. Data fusion: An application in marketing. *Journal of Database Marketing & Customer Strategy Management* 15: 267–284.
- van Hattum, P. und H. Hoijsink. 2009. Improving your sales with data fusion. *Journal of Database Marketing & Customer Strategy Management* 16: 7–14.
- Weber, C. 2014. Google versagt bei Grippe-Vorhersagen. <http://www.sueddeutsche.de/wissen/big-data-google-versagt-bei-grippe-vorhersagen-1.1912226>; Zugriffen: 28. März 2017.
- Wedel, M. und P.K. Kannan. 2016. Marketing Analytics for Data-Rich Environments. *Journal of Marketing* 80: 97–121.
- Wimmer, F. und J. Göb. 2006. Customer Intelligence: Marktforschung und Kundenanalyse als Informationsgrundlage im CRM. In *Grundlagen des CRM. Konzepte und Gestaltung*, Hrsg. H. Hippner und K. D. Wilde, 399–418. Wiesbaden: Gabler.
- Wortmann, C., Fischer, P. M und S. Reinecke. 2016. Too much of a good thing? How Big Data changes managerial decision making in marketing. *EMAC 2016 Proceedings*. Oslo: European Marketing Academy.

Keywords

Big Data, Verhaltens- und Einstellungsdaten, Datenintegration, Kundensegmentierung, Sinus-Milieus, Big-Data-Analytics