

Ralf Wölfle/Petra Schubert (Hrsg.)

**Wettbewerbsvorteile
in der Kundenbeziehung
durch Business Software**

Praxislösungen im Detail

Fallstudien

Konzepte

Modellierung

***E*cademy^{CH}**

Das Kompetenzwerk der
Schweizer Fachhochschulen
für E-Business und E-Government

HANSER

Die in diesem Buch enthaltenen Fallstudien wurden im Rahmen der Initiative eXperience im Jahr 2008 erstellt und an zwei Veranstaltungen, dem eXperience Event in Basel (www.experience-event.ch) und dem Koblenzer Forum für Business Software (www.kofobis.de) präsentiert. Sie wurden wissenschaftlich aufbereitet durch Business-Software-Experten der Fachhochschule Nordwestschweiz FHNW, der Universität Koblenz-Landau, der Universität Bern, der Berner Fachhochschule, der Fachhochschule St. Gallen, der Universität zu Köln, der Universität der Bundeswehr München sowie von Experten aus der Praxis. Die Ecademy (www.ecademy.ch), das Schweizer Kompetenznetzwerk für E-Business und E-Government, unterstützt die eXperience-Initiative (www.experience-online.ch) ideell und finanziell.

www.hanser.de

Bibliografische Information Der Deutschen Bibliothek
Die Deutsche Bibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.ddb.de> abrufbar.

Dieses Werk ist urheberrechtlich geschützt.
Alle Rechte, auch die der Übersetzung, des Nachdruckes und der Vervielfältigung des Buches, oder Teilen daraus, vorbehalten. Kein Teil des Werkes darf ohne schriftliche Genehmigung des Verlages in irgendeiner Form (Fotokopie, Mikrofilm oder ein anderes Verfahren) – auch nicht für Zwecke der Unterrichtsgestaltung – reproduziert oder unter Verwendung elektronischer Systeme verarbeitet, vervielfältigt oder verbreitet werden.

© 2008 Carl Hanser Verlag München
Redaktionsleitung: Lisa Hoffmann-Bäumli
Herstellung: Ursula Barche
Umschlaggestaltung: Büro plan.it, München
Datenbelichtung, Druck und Bindung: Kösel, Krugzell
Printed in Germany

ISBN: 978-3-446-41614-7

14 Mit Kundendaten mehr Nutzen erzeugen

Uwe Leimstoll und Christiane C. Okonek

Kundendaten sind eine wichtige Wissensquelle für Marketing und Kommunikation. Besonders wertvoll sind Daten, die einer bestimmten Person zugeordnet werden können. Sie bilden das „Kundenprofil“. Auf der Basis von Kundenprofilen lassen sich viele Marketing- und Kommunikationsmassnahmen sowie auch die Interaktion mit dem Kunden im E-Commerce individueller gestalten. Die Anpassung der Kommunikation an die individuellen Bedürfnisse eines Kunden wird als „Personalisierung“ bezeichnet. Dieser Beitrag zeigt an zwei unterschiedlichen Beispielen, wie Kundenprofile systematisch aufgebaut, analysiert und für die personalisierte Kommunikation genutzt werden können.

14.1 Wieso Kundendaten?

Kundenbindung ist ein zentrales und zeitloses Schlagwort in Vertrieb und Marketing. Schon seit etlichen Jahren ist in vielen Märkten eine Zunahme der Wettbewerbsintensität zu beobachten. Das zwingt Unternehmen dazu, Kunden langfristig an das Unternehmen zu binden. Denn bekanntlich ist in hart umkämpften Märkten der Erhalt bestehender Kunden mit weniger Aufwand verbunden als die Gewinnung neuer Kunden.

Eng mit der Kundenbindung verknüpft ist die Kommunikation. Die Kommunikation mit Kunden wird im Marketing-Jargon häufig als „Kundendialog“ bezeichnet. Wer mit Kunden in Dialog treten will, kann dies nicht unvorbereitet tun. Kundendialog erfordert Wissen über den Kunden, über seinen Bedarf, über seine Besonderheiten und vieles mehr. Dieses Wissen entsteht mitunter im persönlichen Kundenkontakt, aber es liegt gerade dann nicht als explizites Wissen vor. Häufig ist es nur in den Köpfen der betreffenden Mitarbeitenden vorhanden und steht dann auch nur diesen zur Verfügung. Was also tun, wenn die Kommunikation mit dem Kunden auf eine breitere Mitarbeiterbasis gestellt oder gar automatisiert werden soll?

Das Wissen über den Kunden muss dazu in einer maschinell verarbeitbaren Form – also in Form von Daten – verfügbar gemacht werden. Dies ist mitunter ein sehr aufwändiger und langwieriger Prozess. Alternativ dazu besteht die Möglichkeit, aus Daten, die über Kunden bereits gespeichert sind (also „Kundendaten“), neues Wissen über die Kunden zu generieren.

Jedes Unternehmen verfügt in der Regel über eine Vielzahl von Kundendaten. Dazu zählen in erster Linie Kundenstammdaten und Transaktionsdaten. Diese Daten werden häufig nicht genutzt, um das Angebot stärker an den Bedürfnissen des einzelnen Kunden auszurichten oder den Kundendialog persönlicher zu gestalten. Eine aktuelle Studie über die Nutzung von Kundendaten im E-Commerce, wo durch die Nutzung von elektronischen Plattformen besonders viele Kundendaten erfasst und gespeichert werden, kommt in diesem Zusammenhang zu zwei wichtigen Ergebnissen [Risch 2007]:

- Eine verstärkte Nutzung von Kundendaten würde den Anbietern helfen, sich besser an den Bedürfnissen der Kunden auszurichten.
- Die Ausrichtung von Produkten und Kommunikation an den Kundenbedürfnissen wird für die Anbieter künftig noch wichtiger werden.

Diese Ergebnisse bilden die Motivation für den vorliegenden Fachbeitrag. Er soll zunächst erläutern, welche Quellen von Kundendaten einem Unternehmen zur Verfügung stehen und wie aus den Daten Kundenprofile werden, die eine zielgerichtete Datennutzung erlauben (14.2). Im Anschluss daran geht es um Formen und Varianten der Datennutzung (14.3). Anhand von zwei Beispielen wird beschrieben, mit welchen Methoden Kundenprofile ausgewertet werden und wie die Ergebnisse in konkrete Marketing- oder Kommunikationsmassnahmen einfließen können (14.4 und 14.5). Ein abschliessendes Kapitel (14.6) vergleicht die Methoden und zieht Schlussfolgerungen für ihre Anwendung.

14.2 Aufbau von Kundenprofilen

Kundendaten fallen im Unternehmen zu ganz unterschiedlichen Gelegenheiten an. Transaktionsorientierte Systeme liefern Daten über die verkauften Produkte und darüber, welche Kunden diese Produkte gekauft haben. Weitere Daten sind im Kunden- und Produktstamm gespeichert oder werden in Customer-Relationship-Management-Systemen (CRM-Systemen) vorgehalten. Wer seine Produkte im Internet anbietet, dem stehen weitere Möglichkeiten offen, Kundendaten zu erfassen: In Logfiles, die auf Webservern den Abruf von Webinhalten protokollieren, wird unter anderem gespeichert, welche Produkte ein Kunde in einem Katalog betrachtet hat. Auch Produktbewertungen durch Kunden, die Abfrage von Interessen oder die Einrichtung von Webseiten, auf denen sich Kunden über ihre Erfahrungen mit Produkten austauschen können (so genannte Community-Plattformen,

vgl. Fallstudie buch.ch, S. 201), dienen unter anderem der Gewinnung von Kundendaten.

Werden Kundendaten in verschiedenen Informationssystemen gehalten, stellen sie in der Regel noch nicht den gewünschten Ausgangspunkt für eine Datenanalyse dar. Dazu müssen die Daten vereinheitlicht und zusammengeführt werden. Um kundenbezogene Auswertungen machen zu können, müssen die Kundendaten ausserdem in Bezug zu einem konkreten Kunden gesetzt werden. Erst diese Zuordnung der Daten zu konkreten Kunden führt zum Kundenprofil, das wie folgt definiert wird [Risch 2008, S. 23]:

Ein Kundenprofil umfasst alle relevanten Kundendaten eines Unternehmens, die einer eindeutig bestimmbar Person zugeordnet werden können und die Aufschluss über eine bestehende oder potenzielle Geschäftsbeziehung geben.

Tab. 14.1: Kundenprofile – Quelle: In Anlehnung an Quade et al. [2008, S. 44 ff.]

Profil	Inhalte
<i>Explizite Profile</i>	
Identifikationsprofil	Benutzeridentifikation, Kundenidentifikation
	Adressen (geografisch)
	Demographie, Funktion, Psychographie
Konditionenprofil	Vertrag, Zahlungsart, Versandart
Präferenzprofil	Interessen an Themen oder Produkten
	Katalog- und Sortimentseinstellungen, Einkaufslisten
	Interaktionseinstellungen, bevorzugte Informationskanäle
Gemeinschaftsprofil	Beziehungen, Bewertungen, Meinungen, Inhalte
<i>Implizite Profile</i>	
Transaktionsprofil	Offertanfragen, Käufe, Rücksendungen
Interaktionsprofil	Navigation (Clickstream), Suchanfragen
Verhaltensprofil	Kundenkontakte, Reklamationen, Kommunikationskanäle
	Response-, Kommunikations- und Zahlungsverhalten
Externe Profile	Bonität, Geographische Daten, Konsumentendaten
<i>Kalkulierte Profile</i>	
Verwandtschaftsprofil (Collaborative Filtering)	Nachbarschaftsclique (User-based): Verhaltensmuster
	Produktinteressen (Item-based): Interessensmuster
	Marketingsegmente/-Cluster aus Verhalten & Interessen
Inhaltsprofil (Content-based Filtering)	Produkte: Empfehlungen nach Produktkategorien
	Themen: Empfehlungen nach Themenkategorien

Tab. 14.1 zeigt verschiedene Kundenprofile in einer Systematik, die in Abhängigkeit von der Herkunft und der Art der Daten gebildet wurde. Darin wird zwischen impliziten, expliziten und kalkulierten Profilen unterschieden. Implizite Profile basieren auf Daten, die von Transaktionssystemen oder im Logfile aufgezeichnet werden, ohne dass sich der Kunde dessen bewusst sein muss. Die Daten der expliziten Profile hingegen gibt der Kunde ausdrücklich bekannt. Die kalkulierten Profile wiederum enthalten Daten, die von analytischen Systemen berechnet worden sind und auf deren Basis zum Beispiel Empfehlungen angezeigt werden können.

14.3 Nutzung von Kundenprofilen

Der Aufbau von Kundenprofilen orientiert sich sinnvollerweise nicht (nur) an den im Unternehmen zur Verfügung stehenden Daten, sondern primär am gewünschten Output, der unter Verwendung der Daten erzielt werden soll. Dieser Output besteht in der Regel aus konkreten Marketing- und Kommunikationsmassnahmen, die mit Hilfe des in den Daten gespeicherten Wissens über den Kunden individualisiert werden. „Individualisiert“ bedeutet dabei, dass die Kommunikation mit dem Kunden auf die Bedürfnisse des einzelnen Kunden zugeschnitten wird. Dies wird als „Personalisierung“ bezeichnet. Personalisierung wird heute vor allem im Direktmarketing eingesetzt und im Bereich des E-Commerce.

Je nach Anwendungsgebiet kommen unterschiedliche mathematische Verfahren und Algorithmen zum Einsatz, mit denen die Daten analysiert und die gewünschten Outputs ermittelt werden. Zu diesen Verfahren zählen in erster Linie Filtering-Methoden, wie Collaborative Filtering oder Content-based Filtering, sowie Data-Mining-Methoden.

Die folgenden Abschnitte beschreiben exemplarisch zwei unterschiedliche Anwendungsbereiche und Auswertungsmethoden. In beiden Fällen lassen sich Marketing- und Kommunikationsprozesse durch die Nutzung von Kundenprofilen verkaufsfördernd unterstützen.

14.4 Personalisierte Empfehlungen mit Collaborative Filtering

Die Personalisierung der Kundenansprache gewinnt heute zunehmend an Bedeutung und geht weit über eine persönliche Anrede hinaus. Im E-Commerce bestand die ursprüngliche Idee darin, die vom viel zitierten Tante-Emma-Laden bekannte persönliche Kundenbeziehung technisch nachzuahmen. Daraus entstand eine Fülle von Möglichkeiten, um Inhalte und Funktionen einer Website an die individuellen Bedürfnisse eines Benutzers anzupassen. Diese Anpassung bietet dem Kunden zusätzliche Informationen oder höheren Komfort, die für ihn einen Mehrwert gene-

rieren sollen. Dem Verkäufer erlaubt sie die Umsetzung von Verkaufsstrategien, wie etwa das Cross- und Up-Selling. Darüber hinaus dient die Personalisierung der Verbesserung der Mensch-Maschine-Interaktion. Dabei geht es vor allem um die Verständlichkeit und Bedienbarkeit der Vorgänge auf einer Website.

Um einem E-Commerce-Kunden personalisierte Informationen oder Funktionen anbieten zu können, sind intensive Berechnungen erforderlich. Diese werden umso umfangreicher, je grösser der Kundenbestand, das Sortiment und die Anzahl der Transaktionen sind. Daraus wird ersichtlich, dass solche Berechnungen nicht erst dann ablaufen können, wenn ein Kunde die Website besucht. Stattdessen werden Daten in so genannten Offline-Prozessen nachts, am Wochenende oder auch auf separaten Systemen verarbeitet und anschliessend als kalkulierte Profile (Tab. 14.1) gespeichert. So stehen sie dann für die Echtzeit-Verarbeitung im Onlineshop zur Verfügung.

Damit die Aufteilung von Berechnungen in Offline- und Onlineprozesse funktioniert, werden geeignete Verfahren benötigt. Besonders bewährt hat sich ein Collaborative-Filtering-Verfahren auf der Basis eines Algorithmus (Rechenschema) von Deshpande und Karypis [2004]. Dieses Verfahren basiert ausschliesslich auf Transaktionsdaten, die im Prinzip in jedem Unternehmen vorliegen, das Waren verkauft. Mit Hilfe des Algorithmus werden Ähnlichkeiten zwischen den Artikeln des Sortiments berechnet. Zwei Artikel gelten dann als ähnlich, wenn sie von denselben Kunden gekauft worden sind. Aus diesen noch allgemeinen Ähnlichkeiten lassen sich in einem weiteren Schritt personalisierte Produktempfehlungen berechnen, indem die Ähnlichkeiten zu den Produkten im Transaktionsprofil, Warenkorb oder Clickstream eines Kunden aufaddiert werden. Details dazu schildert die Fallstudie kdmz (S. 187).

Die so berechneten persönlichen Empfehlungen sind in der Regel noch nicht sinnvoll verwendbar. Sie müssen zunächst im Rahmen des Onlineprozesses optimiert werden. Dabei werden zum Beispiel Saisonartikel, nicht auf Lager befindliche Artikel oder Artikel, die der Kunde schon gekauft hat, herausgefiltert. Umgekehrt lassen sich Artikel auch gezielt anbieten, z.B. Artikel, die dem Verkäufer eine höhere Marge bringen oder die aus anderen Gründen abverkauft werden sollen. Die Möglichkeiten hierbei, aber auch die Anforderungen an eine sinnvolle Optimierung, sind vielfältig [Leimstoll/Stormer 2007].

14.5 n-dimensionale Kundensegmentierung mit Data Mining

Die Bildung von kalkulierten Profilen unter Verwendung von online oder offline gewonnenen und angereicherten Kundendaten und eine anschliessende Personalisierung der Ergebnisse ermöglichen die Umsetzung des praxisrelevanten Anspruchs, *dem richtigen Kunden zum richtigen Zeitpunkt ein optimales Angebot*

über seinen bevorzugten Kommunikationskanal zu unterbreiten. Der Nutzen einer solchen differenzierten und individualisierenden Vorgehensweise liegt in einer Reduktion der Kosten pro Kontakt/Anfrage/Auftrag (Cost per Contact/Interest/Order), in einer Optimierung des Angebotsportfolios oder in einer höheren Chance auf Kundenbindung. Womöglich kann auch eine Erhöhung des Share of Wallet erzielt werden. Im optimalen Fall lassen sich Deckungsbeitrag *und* Umsatz erhöhen.

Notwendige Voraussetzung hierfür ist eine mehrdimensionale Segmentierung des Kundenbestands, die die Nachteile einer eindimensionalen, rein quantitativen retrospektiv gerichteten Kundenqualifizierung, wie z.B. einer auf Umsatz basierenden ABC-Kundenklassifizierung, überwindet [Winkelmann 2004]. Mehrdimensionalität meint dabei ganz pragmatisch die Berücksichtigung verschiedener Aspekte aus den Kundenprofilen (vgl. Kapitel 14.2), wie es das anschließende Beispiel verdeutlicht (Abb. 14.1):

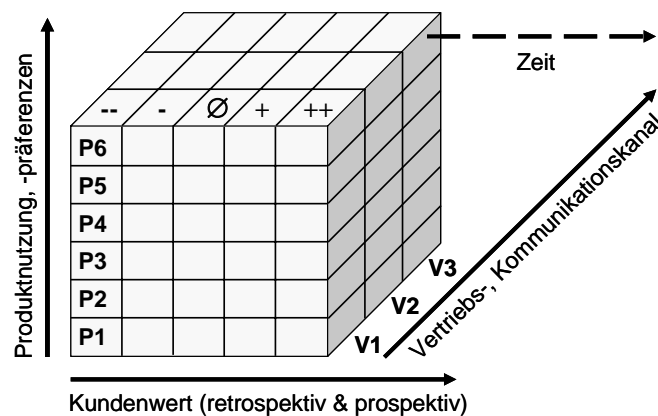


Abb. 14.1: Beispiel eines Kundensegmentierungsansatzes mit 3+1 Dimensionen

Die x-Achse symbolisiert die am Kundenwert orientierte Betrachtung. Der Kundenwert (auch: Customer Value, Customer Lifetime Value) wird häufig mittels einer RFM-Analyse (Recency, Frequency, Monetary) gemessen, ein vor allem im Versandhandel weit verbreitetes Kundenqualifizierungsinstrument. Die y-Achse steht für inhaltliche Produktnutzung und Produktpräferenzen, die z-Achse für den effektiven oder den bevorzugten Vertriebs- oder Kommunikationskanal. Die Zeitachse als vierte Dimension deutet zum einen auf die Veränderungen der gesamten Parameter im Zeitablauf hin. Sie steht zum anderen für das Kaufverhalten (Kaufhistorie, Kauf-Pattern), das sich im Zeitablauf entwickelt und ebenfalls als Parameter im Rahmen der Segmentierung berücksichtigt werden kann. Aufgrund dieser

dynamischen Einflüsse wird offensichtlich, dass es nötig ist, die gesamten Berechnungen auf die n Dimensionen des Würfels in regelmässigen Abständen zu wiederholen.

Die Herausforderung bei einer ausschliesslich auf dem bisherigen Kundenverhalten basierenden Segmentierung besteht in der Modellierung eines bisher nicht oder nur selten vorgekommenen Verhaltens. Dies ist vor allem dann problematisch, wenn abgebildet werden soll, wie Kunden auf eine strategische Umorientierung (z.B. Sortimentsbereinigung), Produktlancierung etc. reagieren. Liegen aussagekräftige Daten aus einer Kundenbefragung vor, können die Ergebnisse von der Stichprobe auf den gesamten Kundenbestand umgelegt, die Kundenprofile also ergänzt werden. Letztlich können somit quantitative retrospektive sowie quantitative und qualitative prospektive Informationen integriert werden.

An die Stelle des im vorhergehenden Abschnitt beschriebenen Collaborative Filtering als methodisches Instrumentarium treten nun andere Algorithmen/Lösungsansätze aus der Statistik und dem Data Mining. Unter Data Mining wird hier der Prozess der Entdeckung und Extraktion von vorher unbekanntem, validem und potenziell nützlichen Informationen aus grossen Datenbeständen verstanden. Diese Informationen werden zur Vorbereitung von Geschäftsentscheidungen ausgewertet [Cabena et al. 1998; Strüby et al. 1999].

Ein Teil der heute verfügbaren Data Mining Tools umfasst nicht nur die Algorithmen, die der explorativen Datenanalyse mit anschliessender Prognose dienen, sondern integriert vollumfänglich die statistischen Verfahren, die zur Überprüfung von Hypothesen oder Annahmen eingesetzt werden. Die folgende Vorgehensweise charakterisiert den Ablauf jedes Analyseprojekts (Tab. 14.2):

Tab. 14.2: Systematische Arbeitsschritte in Data-Mining-Projekten – Quelle: SPSS: CRISP-DM [Chapman et al. 2000]

Business Understanding	Formulierung des eigentlichen Projektziels aus der Perspektive des Anwenders.
Data Understanding	Datenauswahl gefolgt von Aktivitäten mit dem Ziel, die Daten kennenzulernen, Probleme der Datenqualität oder interessierende Teilmengen der Daten zu entdecken.
Data Preparation	Aktivitäten zur Generierung der endgültigen Analysedaten. Darin enthalten ist die Auswahl von Daten, sowohl von Variablen als auch von Datensätzen, wie auch Transformationen und das Entfernen von Datenschmutz.
Modelling	Auswahl und Anwendung verschiedener Verfahren sowie Festsetzung der zugehörigen Parameter.
Evaluation	Gründliche Beurteilung der vorhergehenden Schritte um sicherzustellen, dass die Ergebnisse der vorgegebenen Zielsetzung gerecht werden.
Deployment	Aufbereitung des gefundenen Wissens in einer dem Auftraggeber verständlichen Form.

In der anschliessenden Tabelle stehen die für das mehrdimensionale Segmentierungsbeispiel denkbaren Analyseschritte, Methoden und Resultate (Tab. 14.3). Die Schattierungen in der Tabelle gruppieren die Kennzahlen nach den Dimensionen der Abb. 14.1. Weitere Anwendungsbereiche und Methoden beschreiben Witzig und Okonek [2007, S. 17]. Die eigentliche Segmentierung wird dann unter Verwendung clusteranalytischer (Gruppen bildender) Verfahren über diese Kennzahlen berechnet.

Tab. 14.3: Kennzahlen für eine mehrdimensionale Segmentierung

Analyseschritte	Methoden	Resultate (Kennzahlen)
Datenaufbereitung, -transformation	Diverse, Transform, Validate, feature Select	Ausgangsdatei für Modellierung, transponierte Matrix
Gewinnprognose	Time Series Modeler mit automatischer Algorithmenauswahl	z.B. Prognosewerte für die nächsten 24 Monate, die nächsten 3 Quartale etc.
Umsatzprognose		
RFM (Recency, Frequency, Monetary)	RFM Analysis	Score = \sum gewichtete R,F,M = $(R \cdot G_1) + (F \cdot G_2) + (M \cdot G_3)$
Prognose Restlänge Kundenlebenszyklus (Customer Life Cycle)	Kaplan-Meier (für \emptyset -Survival pro Segment)	Prognose: Überlebenswahrscheinlichkeit pro Segment
	Cox-Regression	Überlebenswahrscheinlichkeit pro Kunde für nächstes Jahr
	Entscheidungsbäume (für Kündiger ja/nein)	Differenzierungsregeln, Prognose: kündigt ja/nein
Kundenwert	\sum der aktuellen und zukünftigen, mit Hilfe eines Abzinsungsfaktors $(1/(1+i)^n)$ abdiskontierten Gewinne oder Umsätze	
Loyalität	Treuejahre / Alter * Anzahl Teilmärkte	Score, möglicher Gewichtungsfaktor für den Kundenwert
Kanalpräferenz	Deskriptive Statistiken	Verteilung, Kanaluordnung
Next-best-product, Next-best-buy	Sequenzanalyse, A priori, Carma (Continuous Association Rule Mining Algorithm)	Warenkörbe, Kaufvorhersagen und -chancen pro Kunde
Produktpräferenz	Peer Group Analysis, Self-Organizing Maps	Interessens-Cluster
Kontakt-/Kaufmuster	Mustererkennung in Historie, Quotient	(relatives) Verhaltensmuster Kontaktzeitpunktempfehlung

Bereits bei quantitativen Kennzahlen wie dem Kundenwert ist der Charakter der Transaktionsdaten ausschlaggebend für das später erreichbare Qualifizierungsniveau. Liegen z.B. keine Umsatzdaten auf Monatsebene über längere Zeiträume vor und lassen sie sich auch nicht inhaltlich vertretbar dahingehend aggregieren, so sind Zeitreihenanalysen mit entsprechenden Prognosen nicht durchführbar. An die Stelle einer dynamischen, quantitativ prospektiven Kundenqualifizierung kann dann nur eine statische Kennzahl treten, die ausschliesslich quantitativ retrospektive Informationen verwertet, wie z.B. der RFM Score. Dies erschwert die Beurtei-

lung des Entwicklungspotenzials beim Kunden und die Kalkulation von Kundensegmenten unter Berücksichtigung der Entwicklungspotenziale.

Der Fokus liegt hier aber auf der Produktnutzung, den Produktpräferenzen und den daraus abgeleiteten Empfehlungen. Die Warenkorbanalyse ist eine klassische Data-Mining-Aufgabe. Dabei werden Produktkombinationen erkannt, Assoziationsregeln aufgestellt und personalisierte Produktvorhersagen getroffen. Je nach angewendetem Verfahren kann dabei auch die Reihenfolge des Produkterwerbs berücksichtigt werden (Sequenzanalyse). Verwendung findet die Warenkorbanalyse bei der Angebotsoptimierung und Produktentwicklung. Die personalisierten Empfehlungen im Sinne eines Next-best-buy unterstützen die individualisierte Kundenansprache und die Optimierung der Kundensegmentierung.

SPSS Clementine, als Beispiel für eine Data-Mining-Software, setzt für vier Anwendungen der Warenkorbanalyse drei Assoziationsregel-Algorithmen ein [SPSS 2007]. Die optimale Algorithmenwahl ist abhängig von den Charakteristika der Datenbasis. Im Ergebnis liefern alle Algorithmen Regeln mit Angaben zu deren Vorkommen und Verlässlichkeit. Diese Ergebnisse bilden eine sehr gute Entscheidungsbasis für den Einsatz der Regeln zur Produktprognose. Eine solche Regel kann beispielsweise wie folgt lauten:

If Produkt1 & Produkt3 then Produkt2 (& Produkt4)

Das Ergebnis solcher Regeln sind dann einerseits die Kombinationen der Produkte, die überdurchschnittlich häufig zusammen gekauft werden (Warenkörbe). Daraus lassen sich Schlüsse ziehen für die Gestaltung und Präsentation von Sortimenten. Andererseits lassen sich mit Hilfe der Regeln auch personalisierte Empfehlungen generieren.

14.6 Anwendung von Personalisierung und Segmentierung

Die beiden Beispiele der vorhergehenden Kapitel sollen deutlich machen, dass es sehr unterschiedliche Ansätze gibt, um Kundendaten zur Verkaufsförderung zu nutzen. Ausgangspunkt ist in beiden Fällen der Aufbau systematischer Kundenprofile, in denen die Daten konkreten Personen zugeordnet werden. Dies ist eine wichtige Voraussetzung, um die Bedürfnisse der eigenen Kunden, ihr Verhalten und ihren Wert besser kennen zu lernen. Zukünftig wird dieser Aspekt immer wichtiger werden, um sich einen Wettbewerbsvorteil gegenüber den Mitbewerbern zu sichern.

Die Personalisierung im Kundendialog fokussiert sehr stark die Automatisierung der Kommunikation. Ihr Einsatzgebiet liegt heute schwerpunktmässig noch im E-Commerce, zunehmend aber auch im CRM. Für die Realisierung von Empfehlungssystemen hat sich – neben dem Verfahren des Content-based Filtering – das

Collaborative Filtering bewährt, das zwar bei der Einführung einen gewissen Initialaufwand bedingt, später aber weitgehend automatisiert abläuft. Ein Vorteil dieses Verfahrens sind auch die geringen Anforderungen an die Daten und deren Pflege. Schon einfache Transaktionsdaten reichen mitunter aus, um mit einigen ergänzenden optimierenden Regeln gute Empfehlungen zu generieren.

Eine n-dimensionale Kundensegmentierung mit Hilfe von Data-Mining-Verfahren erschliesst ein breiteres Anwendungsfeld. Vor allem im Marketing haben sich diese Verfahren durchgesetzt, um grosse Datenbestände nach sinnvollen Informationen zu durchforsten. Die Ziele bestehen hier schwerpunktmässig in der optimalen Allokation von Budgets und in der Vermeidung von Streuverlusten. Anwendungen liegen in der Produktentwicklung, in der Gestaltung von Produktportfolios, in allen Bereichen der Marktbearbeitung und ebenfalls in der Personalisierung.

In der Praxis nutzen Warenhäuser die Ergebnisse einer auf Kassensbondaten basierenden Warenkorbanalyse, um ihr Angebot zu optimieren oder optimal zu positionieren. In der Telekommunikationsbranche, aber auch in Banken und Versicherungen, werden Cross- und Up-Selling-Vorschläge zum Teil in Echtzeit in eine Call-Center-Software integriert oder dem Kundenberater (tagesaktuell) zur Verfügung gestellt.

Grundsätzlich kann nahezu jedes Unternehmen auf dem Komplexitätsniveau seiner Kundendaten von Kundensegmentierung und Personalisierung profitieren. Essentiell ist jedoch die Bereitschaft zur systematischen Pflege und Aktualisierung der Daten. An erster Stelle stehen da die Adressdaten, ohne die kein erfolgversprechender Kundenkontakt möglich ist. Kundenadressen können via Portale wie AdressenPlus.ch aktualisiert und mit sozio-demographischen Informationen, Kommunikationsdaten etc. angereichert werden. Bereits auf der Basis dieser angereicherten Informationen können rudimentäre Kundenprofile erstellt werden. Aus Transaktions- und Verhaltensprofilen lässt sich zum Beispiel der RFM Score bilden.

Wichtig bei der Nutzung sowohl von Collaborative Filtering als auch von Data Mining ist der menschliche und statistische Sachverstand. Die von den Verfahren berechneten Ergebnisse müssen hinsichtlich ihrer Stichhaltigkeit und Verwendbarkeit beurteilt werden. Bei komplexeren Data-Mining-Verfahren, wie zum Beispiel einem Sequenzalgorithmus, muss darüber hinaus eine Reihe von statistischen Masszahlen interpretiert werden können. Dazu wird ein nicht zu unterschätzendes Know-how benötigt.