

Vom E-Commerce lernen: RFID und Smartphone als Konversionsoptimierer im stationären Modehandel

Bearbeitet von
Niklas Dorn

1. Auflage 2015. Taschenbuch. 124 S. Paperback

ISBN 978 3 95485 310 6

Format (B x L): 15,5 x 22 cm

[Wirtschaft > Wirtschaftssektoren & Branchen: Allgemeines > Einzel- und Großhandel](#)

schnell und portofrei erhältlich bei

The logo for beck-shop.de features the text 'beck-shop.de' in a bold, red, sans-serif font. Above the 'i' in 'shop' are three red dots of increasing size. Below the main text, 'DIE FACHBUCHHANDLUNG' is written in a smaller, red, all-caps, sans-serif font.

beck-shop.de
DIE FACHBUCHHANDLUNG

Die Online-Fachbuchhandlung beck-shop.de ist spezialisiert auf Fachbücher, insbesondere Recht, Steuern und Wirtschaft. Im Sortiment finden Sie alle Medien (Bücher, Zeitschriften, CDs, eBooks, etc.) aller Verlage. Ergänzt wird das Programm durch Services wie Neuerscheinungsdienst oder Zusammenstellungen von Büchern zu Sonderpreisen. Der Shop führt mehr als 8 Millionen Produkte.

Leseprobe

Textprobe

Kapitel 3.4, Konzept zur Echtzeit-Konversionsratenoptimierung im stationären Modehandel

Wie im vorherigen Abschnitt 3.3 gezeigt, bieten RFID, Smartphones und Big Data bzw. neue Empfehlungsalgorithmen das Potenzial die Techniken zur Erfassung des Kundenverhaltens und der personalisierten Ansprache auf den stationären Modehandel zu übertragen. So ermöglicht RFID produktgenaues Tracking. Das Smartphone ermöglicht die Identifikation eines Kunden und möglicherweise Rückschlüsse auf sein Kaufverhalten. Empfehlungsalgorithmen ermöglichen die automatische Erstellung personalisierter Angebote und Big Data ermöglicht die Auswertung und Reaktion in Echtzeit

Eine konkrete Möglichkeit RFID, Smartphones und Empfehlungsalgorithmen zu verknüpfen und zur Steigerung der Konversionsrate im stationären Modehandel einzusetzen, besteht in folgendem Konzept

Die Umkleidekabinen eines stationären Modegeschäfts werden mit RFID-Lesegeräten ausgestattet. Zudem werden alle Kleidungsstücke mit RFID-Tags versehen. Die entsprechenden Produktdaten sind in einer Produktdatenbank angelegt und sind zentral abrufbar. Neben den RFID-Lesegeräten und Tags wird über lokales W-LAN eine an das System angebundene Smartphone Anwendung bereitgestellt. Mit Hilfe der Anwendung und einem im Hintergrund arbeitenden und auf Data-Mining Techniken basierenden Empfehlungsalgorithmus werden Kunden via ihre Smartphones produktgenaue, automatische und kundenindividuelle Angebote und Rabatte in Echtzeit ausgespielt. Im ersten Schritt richten diese sich nach der Produktauswahl, dem Kundenverhalten und dem Kundenprofil. Im weiteren Verlauf auch nach der Kundenhistorie. Die Erkennung der Produktauswahl erfolgt durch das Auslesen der RFID-Tags durch die in den Umkleidekabinen installierten RFID-Lesegeräte. Die Fokussierung auf die Umkleidekabine empfiehlt sich aus zwei Gründen: Einerseits bietet sich durch die klare Fokussierung die Möglichkeit, die Datenmenge und damit die Komplexität zu reduzieren, die bei sonstiger Ausstattung der gesamten Verkaufsfläche mit Lesegeräten schnell sehr große Dimensionen annehmen würde und damit schwer steuerbar wäre. Durch die klare Beschränkung lässt sich zudem eine erhebliche Kostenreduzierung realisieren. Gleichzeitig gilt die Umkleidekabine unter Experten als der physische Ort im stationären Modehandel, an dem die Kaufentscheidung durch den Kunden getroffen wird. Damit ist sie von höchster Relevanz für den Einkaufsvorgang im stationären Handel (Wegner o.D.)

Startet ein Kunde nun in der Umkleidekabine die Smartphone-Anwendung, werden ihm die durch

RFID-Lesegeräte erfassen Produkte automatisch zugeordnet. Passend zu den Produkten werden ihm individuelle Angebote ausgespielt. Denkbar sind hier vor allem Cross- und Upselling Angebote, welche sowohl auf der aktuellen Auswahl des Kunden, als auch auf seinem Kundenprofil bzw. seiner Kundenhistorie basieren. Wurde beispielsweise erkannt, dass ein Kunde Hemden anprobiert, können ihm nach dem Prinzip des Content-based Filterings, passend dazu Krawatten angeboten werden. Auch weitere Informationen zu den Produkten können abgerufen werden. Geht aus der Kundenhistorie hervor, dass der Kunde häufig auch T-Shirts kauft, wenn er Hemden anprobiert, könnten ihm dazu passende Rabatte angeboten werden. Empfehlungen können auch auf dem Prinzip des Collaborative Filterings basieren. Ähneln Kunden anderen Nutzern durch ihr Verhalten und/ oder ihr Profil, können ihnen Produkte angeboten werden, die andere ihm ähnliche Nutzer gekauft haben. Über Collaborative Filtering, die Analyse der Kundenhistorie und vor allem des aktuellen Kundenverhaltens ist es darüber hinaus möglich Rückschlüsse, auf das Budget, die individuelle Zahlungsbereitschaft und die Kaufwahrscheinlichkeit eines Kunden zu ziehen. Liegt beispielsweise die Zahlungsbereitschaft eines Kunden für eine bestimmte Produktkategorie niedriger, als der Preis der von ihm ausgesuchten Produkte, könnten gezielt Rabatte gegeben werden, um so den Preis an die persönliche Zahlungsbereitschaft anzupassen, die Kaufwahrscheinlichkeit dadurch zu erhöhen und so letztlich die Konversionsrate zu steigern

3.5: Kaltstart-Problem

3.5.1: Problematik

Die Grundlage für die Ausspielung automatischer, individueller Empfehlungen passend zum Kundenverhalten, bildet im hier dargelegten Konzept ein Empfehlungsalgorithmus. Dieser basiert auf der Auswertung von verhaltens- und produktbezogenen Kundendaten mittels Techniken des Data-Minings. Ein Kriterium für die Anwendung von Data-Mining Techniken sind große Datenbestände, anhand derer dann Muster und Zusammenhänge mathematisch-statistisch errechnet werden können. Ohne eine solide Datenbasis, welche das Kundenverhalten dokumentiert, lässt sich somit kein Data-Mining mit dem Ziel automatischer, individueller Empfehlungen betreiben. Genau hierin liegt die Schwierigkeit des beschriebenen Szenarios. Da mit der Neueinführung der hier beschriebenen Anwendung weder Daten zum Kundenverhalten noch zur Kundenhistorie vorliegen, können auch keine darauf basierenden individuellen Produktempfehlungen ausgesprochen werden. Erst mit einer wachsenden Anzahl an Kundeninteraktionen ist es möglich anhand der generierten Daten Data-Mining Techniken anzuwenden und Empfehlungen auszuspielen. Man spricht hier deshalb auch von einem sogenannten Kaltstart-Problem. (Inaba 2009, S. 97) (Schein et al. 2002) (Desrosiers und Karypis op. 2011, S. 131) (Masthoff op. 2011, S. 695) Nachfolgend wird daher nach einer Lösung zur Überwindung des Kaltstart-Problems gesucht

3.5.2, Lösungsansatz

Grundsätzlich gibt es mehrere Verfahren, die zur Lösung des Kaltstart-Problems im Szenario geeignet sind. Daher werden nachfolgend die Vor- und Nachteile der verschiedenen Verfahren betrachtet und anschließend ein geeignetes Verfahren ausgewählt, mit dem im weiteren Verlauf eine Lösung entwickelt wird

Eine Möglichkeit zur Lösung des Kaltstart-Problems ist es Heuristiken einzusetzen, um auf Kundenverhalten und -interessen zu schließen. Die so gewonnen Annahmen lassen sich in Form von Bedingungen und Regeln sogenannter Business Rules formulieren und zur Entwicklung eines Empfehlungsalgorithmus verwenden. Nach dem „Trial and Error“ Prinzip lassen sich die Business Rules bzw. der Empfehlungsalgorithmus im Praxisbetrieb solange validieren, überarbeiten und optimieren bis wirksame Empfehlungen entwickelt worden sind, welche die Konversionsrate zu steigern vermögen. Die Vorteile des Verfahrens liegen vor allem in der Einfachheit und der leichten Umsetzbarkeit. Ein oder mehrere Experten stellen dabei Hypothesen auf, die auf eigenen Erfahrungswerten basieren. Diese Hypothesen werden als Bedingungen ausgedrückt und zur Entwicklung eines Algorithmus eingesetzt. Der entscheidende Nachteil des Verfahrens liegt in der starken Abhängigkeit von der Kompetenz der Experten. Methodisch bedingt kann es dabei zu sehr großen Ungenauigkeiten bis hin zu groben Fehleinschätzungen kommen, die schließlich, ausgedrückt in falschen Business Rules, zu suboptimalen Empfehlungen führen können. Es besteht also die Gefahr, durch irrelevante Angebote Kunden zu verärgern und sie möglicherweise ganz zu verlieren. Dadurch ist es letztlich möglich die Konversionsrate negativ zu beeinflussen, anstatt diese, wie angestrebt, durch individuelle Angebote zu steigern

Eine zweite Möglichkeit liegt darin, Kundenprofile von Neukunden anzulegen und diese mit Kundenprofilen von Bestandskunden abzugleichen. Vor erstmaliger Nutzung müssen Kunden zunächst persönliche Daten zur Profilbildung angeben. Mit Hilfe dieser Daten werden Nutzerprofile erstellt. Anhand der Nutzerprofile werden Kunden bestimmten Segmenten zugeordnet. Sobald eine gewisse Zahl an Profilen vorhanden ist und Daten zum Nutzerverhalten aufgezeichnet wurden, können Nutzer nach dem Prinzip des Collaborative Filterings segmentiert werden. Je nach zugeordnetem Segment erhalten Kunden andere Angebote. Das bedeutet, dass Nutzer, die sich aufgrund ihres Profils und oder Verhaltens sehr ähnlich sind, ähnliche Angebote erhalten. (Masthoff op. 2011, S. 695) Auch bei diesem Verfahren sind mehrere Nachteile anzuführen

Zu Beginn erfolgt die Segmentierung hier ebenfalls durch Heuristik, da keine historischen Nutzerdaten vorliegen. Dadurch besteht bei der Anwendung dieses Verfahrens die Gefahr unpassende Angebote auszuspielen und die Konversionsrate damit negativ zu beeinflussen. Kritisch zu bewerten ist auch, dass Kunden aktiv Profile erstellen müssen. Denn nur so lässt sich eine Segmentierung anhand von persönlichen Informationen durchführen. Das kann als

Einstiegsbarriere wirken und damit die erstmalige Registrierung potenzieller Nutzer verhindern. Darüber hinaus sind auch bei diesem System die Empfehlungen erst bei wachsender Nutzerzahl wirkungsvoll.