

Die Wechselbereitschaft von Energiekunden automatisch erkennen

Thomas Reith

Im Energiemarkt kommt es vor allem darauf an, die einträglichen Kunden zu halten. Denn neue Kunden zu gewinnen ist im herrschenden Verdrängungswettbewerb deutlich aufwendiger und teurer. Konsequentes Data-Mining mit erweiterter Datenbasis kann hier wertvolle Hinweise zur differenzierten Analyse des eigenen Kundenstamms liefern. In Verbindung mit moderner IT-Ausstattung wird so wirksam eine hohe Kundenloyalität erreicht, die nicht auf Kosten der Profitabilität geht.

Direkt nach der Liberalisierung des Energiemarktes im Jahre 1998 bildeten die Ungewissheit und Ängste, bspw. in Bezug auf die Versorgungssicherheit, für viele Verbraucher noch eine gewisse Wechselbarriere. Heute spielt dies nur noch eine untergeordnete Rolle. Verbraucher sind in dieser Hinsicht deutlich aufgeklärter und kennen die rechtlichen Rahmenbedingungen. Zu diesem Ergebnis kommt auch eine Delphi-Befragung [1] der Unternehmensberatung Accenture GmbH aus dem Jahr 2008 [2]: „Die Wechselbereitschaft der Privatkunden wird deutlich zunehmen“.

Dazu kommt in den Zeiten von Internet und Web 2.0 das sich zunehmend wandelnde Kundenverhalten. Die globale Verfügbarkeit von Informationen und der dadurch tendenziell höhere Informationsstand begünstigen die Wechselbereitschaft der heutigen Kunden [3]. Preisvergleichsportale bspw. gibt es in großer Zahl für unterschiedlichste Märkte. Insgesamt sind die Verbraucher somit preisensibler und deutlich schneller bereit, den Anbieter zu wechseln. Dies verdeutlicht auch eine Studie des Bundesverbands der Energie- und Wasserwirtschaft (BDEW) [4] aus dem Jahr 2007, die auf den Trend der steigenden Wechselquote hinweist (Auszug: Abb. 1).

CRM und Kundenbindung

Um diesen Herausforderungen gerecht zu werden, setzen Unternehmen zunehmend auf das Customer Relationship Management (CRM), was die konsequente Ausrichtung des Unternehmens auf die Kundenbedürfnisse bezeichnet. Die Entwicklungen im IT-Hardware-Bereich führen zudem dazu, dass Zugriffszeiten schneller, Speicherkapazität immer günstiger und Datenbanken effizienter werden. Es lassen sich somit immer größere Datenmengen speichern und verarbei-

ten sowie Informationen aus verschiedenen Datenquellen zusammenführen. Dieses Vorgehen hat dazu beigetragen, dass der Kunde dem Unternehmen gegenüber grundsätzlich transparenter wird, bisher waren daraus aber noch keine Handlungsempfehlungen ableitbar. Die Kernaufgabe für das Projekt der Wilken GmbH und der Hochschule Ulm lautete also, Wechselstendenzen frühzeitig zu erkennen und mögliche Faktoren auffindig zu machen.

Das Projekt baut auf den Erfahrungen einer ersten Arbeit von Dimitri Galaschin (Wilken GmbH) auf, bei dem u. a. bereits verschiedene Klassifikationsverfahren validiert wurden. Im Gegensatz zu vielen naturwissenschaftlichen Prozessen spielen bei einer Entscheidung zu einem Anbieterwechsel vielschichtige persönliche und psychologische Einzelfaktoren eine Rolle, die schwer oder gar nicht zu identifizieren sind. Spannend war hierbei die Frage, inwiefern es zumindest nahezu allgemeingültige Indikatoren und typische Umgebungsvariablen gibt, die auf eine bevorstehende Entscheidung zum Anbieterwechsel hindeuten.

Ziel des sog. Churn-Management ist es, diese Wechselstendenzen im Auge zu behalten, und evtl. auch Gegenmaßnahmen einzuleiten. Churn-Management ist ein Kunstwort aus „Change“ und „Turn“ und bezeichnet die Strategie wie ein Unternehmen sowohl mit Kündigern als auch mit kündigunggefährdeten Kunden umgeht. Eine wichtige Methodik kann an dieser Stelle die regelmäßige Identifikation von kündigunggefährdeten Kunden sein [5]: „Although churn as a whole is an unavoidable phenomenon, it can be managed and the potential losses to the business can be minimized. The timely detection of possible churners, together with effective retention efforts support this goal.“

Die CRM-Systeme der Unternehmen bieten meist eine erste Datenbasis. Die Schwierigkeit besteht in der Auswertung und Interpretation der Informationen. Hier haben sich Verfahren zum maschinellen Lernen als vielversprechender Ansatz herausgebildet. Im vorliegenden Artikel soll getestet werden, inwieweit Data-Mining-Verfahren zu den genannten Fragestellungen Antworten bieten können.

Data-Mining

Data-Mining verbindet Elemente der Statistik, der künstlichen Intelligenz sowie des maschinellen Lernens und ist damit ein interdisziplinäres Forschungsfeld. Grundlage hierfür ist die systematische Analyse von großen Datenmengen, um bisher unbekanntes Wissen in Form von Mustern, Strukturen oder Regeln zu finden. Kern der Data-Mining-Verfahren sind mathematische und statistische Methoden.

Diese werden in verschiedenen Algorithmen angewandt und sind je nach Anwendungsfall auszuwählen. In Abgrenzung zum traditionellen maschinellen Lernen sind Data-Mining-Verfahren in der Lage, selbst Hypothesen zu generieren. Deshalb spricht man in diesem Zusammenhang auch von proaktiven Verfahren. Als Vorgehensmodell empfiehlt sich das CRISP-DM (Cross-Industry Standard Process for Data-Mining)-Modell, das einem evolutionären Ansatz folgt.

Entscheidungsbäume zur Klassifikation

Unter den verschiedenen Data-Mining-Verfahren wurde das Hierarchisierungsmodell der Entscheidungsbäume zur Klassifikation der Kündiger gewählt. Entscheidungsbäu-

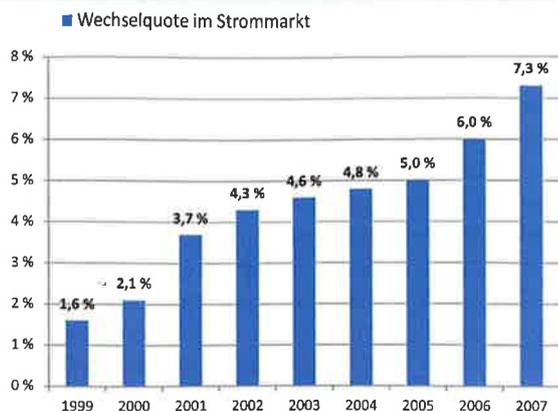


Abb. 1 Die BDEW-Studie aus dem Jahr 2007 diagnostizierte schon steigende Wechselquoten

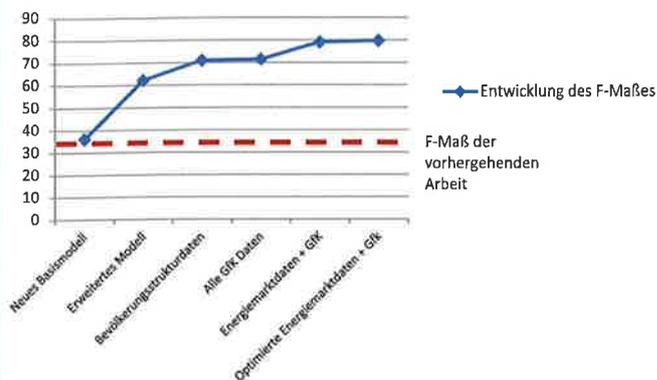


Abb. 2 Die Entwicklung des F-Maßes in den verschiedenen Stufen des Modellierungsprozesses

me gehören zu den hierarchischen Klassifikatoren und überprüfen damit nicht einzelne Merkmale gleichzeitig, sondern arbeiten diese anhand ihrer Wichtigkeit nacheinander ab. Grundlage für eine Klassifikationsanalyse ist eine Datenbasis mit vielen Objekten (Kunden) und zugeordneten Merkmalen. Diese Objekte sind nun zwei oder mehreren Klassen (Kündiger ja oder nein) zurechenbar.

Entscheidungsbäume als Klassenmodelle sind sehr strukturiert sowie nachvollziehbar aufgebaut und damit als Klassifikatoren sehr beliebt. Da die Klassifikationsanalyse zudem für viele Anwendungsfelder geeignet ist, sind Entscheidungsbäume mittlerweile eines der am häufigsten genutzten Data-Mining-Verfahren. Auf Basis von Trainingsdaten wird hierbei ein Entscheidungsbaum erstellt, der wiederum dafür genutzt werden kann, die Kündigungswahrscheinlichkeit von bestehenden Kunden zu bewerten. Die Trainingsdaten enthalten dabei Kundendaten von Kündigern aus der Vergangenheit, wie auch Daten von treuen Kunden. Um eine Aussage über die Qualität der Vorhersage treffen zu können, wird die Prognosequalität mehrfach validiert. Hierzu wird der Entscheidungsbaum auf historische Daten angewandt und die einzelnen Fehlklassifikationen bewertet.

Durchführung des Data-Mining

Erste Grundlage für die Data-Mining-Analysen sind typische Kundendaten aus dem Kundenstamm. Die Vorhersagequalität

kann durch den Einbezug von Daten aus dem CRM-Bereich weiter gesteigert werden. Attribute können hier bspw. die Anzahl der Beschwerden oder auch die bisherige Vertragsdauer sein. Nachdem alle internen Attribute ausgeschöpft sind, stellt sich die Frage nach weiteren Möglichkeiten, das Vorhersagemodell zu verbessern. Die zentrale Idee ist hierbei die Anreicherung mit externen Daten.

Da die Datenqualität und die Menge an verfügbaren Daten in CRM-Systemen in diesem Kontext oft unzureichend ist, können die Daten meist die wirtschaftlichen und sozialen Rahmenbedingungen nicht hinreichend abbilden. Hier knüpft die Idee der Anreicherung der internen Daten mit externen Datenbeständen an. Dadurch können weitere Informationen im Rahmen des Data-Mining verwendet werden. Der Schluss liegt nahe, dass diese die Vorhersagequalität des Modells nochmals steigern würden. Externe Daten beschreiben meist moderierende bzw. erklärende Variablen, die nicht im Einflussbereich des Unternehmens stehen [6].

Dazu gehören im besonderen Maße soziodemografische Strukturen. Von diesen ist ein Einfluss auf das Kundenverhalten, insbesondere auf die Wechselbereitschaft zu erwarten [7]. Auch die Verfügbarkeit von attraktiven Alternativen scheint in einer ersten Überlegung Einfluss auf das Kundenverhalten zu haben. Diese werden durch die Angebote der Wettbewerber beschrieben. Man könnte also von der Hypothese ausgehen, dass bei deutlich günstigeren Angeboten

der Wettbewerber die Wechselbereitschaft des Kunden zunimmt.

Grundlage hierfür ist, dass monetäre und nichtmonetäre Wechselkosten, wie etwa der Vertrauensverlust bei einer langjährigen Kundenbeziehung, oder auch Opportunitätskosten, wie bspw. ein Treuebonus für langjährige Kunden, durch ein erheblich günstigeres Angebot kompensiert werden. Dabei schaffen Neukundenboni der Wettbewerber zusätzliche Anreize. Im weiteren Vorgehen werden deshalb sowohl soziodemografische Daten als auch Energiemarktdaten in das Data-Mining-Modell integriert.

Auswertung

Bei der Durchführung der Datenanalysen hat sich die Dauer der Kundenbeziehung als ein wertvoller Indikator der Wechselbereitschaft herausgestellt. Die Beobachtung deckt sich ebenfalls mit bestehenden Studien. Das auf den internen Daten basierende Klassifikationsmodell konnte bereits eine gute Prognosequalität vorweisen. Mit einer Trefferquote von 58,28 % konnten mehr als die Hälfte der gekündigten Verträge identifiziert werden. Ein solches Ergebnis war a-priori zunächst nicht zu erwarten. Die Qualitätsbewertungen erfolgten anhand qualifizierter statistischer Verfahren.

Dabei ist festzustellen, dass eine Bewertung meist nur unter Berücksichtigung mehrerer Kenngrößen erfolgen kann und eine Abhängigkeit zum Anwendungskontext besteht. Eine wichtige Kenngröße ist hierbei die

Trefferquote, die aussagt wie viele tatsächliche Kündiger identifiziert werden konnten. Ergänzend spielt aber auch die Präzision eine Rolle, die angibt, wie viele als kündigunggefährdet eingestufte Kunden tatsächlich nicht kündigen wollten.

Das F-Maß verdichtet beide Kennzahlen zu einer einzigen Messgröße, um die Qualität eines Klassifikationsmodells zu bewerten. Dabei kann eine individuelle Gewichtung festgelegt werden, die sehr vom Anwendungskontext abhängig ist. Im vorliegenden Projekt wurde die Trefferquote doppelt so stark gewichtet wie die Präzision. Bei kostenintensiven Marketingkampagnen kann aber durchaus auch ein stärkerer Fokus auf die Präzision gelegt werden.

In Abb. 2 ist der Verlauf des F-Maßes über die verschiedenen Ausbaustufen dargestellt. Die Trefferquote lag bei dem finalen Modell bei einem sehr hohen Wert von ca. 79 %. Nach dem erfolgreichen Redesign sollten die angestellten Hypothesen bzgl. des Einflusses externer Daten auf das Klassifikationsmodells geprüft werden. Bei der tiefergehenden Analyse haben sich zum einen die soziodemografischen Daten aus dem Bereich des Geomarketing, als auch die Energiemarktdaten in Bezug auf den Wettbewerb als geeignete Ansatzpunkte herausgestellt.

Bei der Integration der soziodemografischen Daten hat sich gezeigt, dass zunächst eine sinnvolle Granularität der Daten festgelegt werden muss. Der soziologischen Theorie des „Neighbourhood-Effektes“ folgend fiel die Entscheidung hierbei auf die Verwendung der Ebene der Straßenabschnitte. Feinere Granulierungen müssen in jedem Fall genau geprüft werden, da oftmals keine hinreichend aussagekräftige Datenbasis berücksichtigt wird. Vielmehr wird an dieser Stelle oft mit weiteren statistischen Verteilungen gearbeitet, weshalb dieses Vorgehen nur in wirklichen Ballungsräumen sinnvoll erscheint.

Neben der Auswahl der richtigen Daten bildet das „Data Matching“ den nächsten Schritt. In dem vorliegenden Anwendungsfall konnte die Adresscodierung zufriedenstellende Ergebnisse liefern. Die Qualität dieser Zuordnung hat, nach Festlegungen zur Nomenklatur, die Erwartungen übertrof-

fen. Bei der Auswahl der geeigneten Attribute wurde deutlich, dass diese auf Abhängigkeiten zu prüfen sind, um unnötig komplexe Klassifikationsmodelle und lange Laufzeiten zu vermeiden. Insgesamt zeigt sich aber bei der Berücksichtigung der soziodemografischen Merkmale ein deutlicher Einfluss auf die Wechselneigung. Die Qualität des Klassifikationsmodells profitiert stark von den additiven Informationen. Die Trefferquote konnte um ca. 11,65 Prozentpunkte gesteigert werden. Zusätzliche soziodemografische Merkmale haben anschließend keine deutliche Verbesserung mehr ergeben.

Nachdem der Einfluss der soziodemografischen Daten belegt werden konnte, wurde der Einfluss der energiemarktbezogenen Daten getestet. Bei der Auswahl des Formates der externen Daten hat sich gezeigt, dass die Berechnung eines bepreisten Verbrauches durch die zahlreiche Tarifmodelle eine eigenständige Komplexität darstellt. Aufgrund dessen ist die Arbeit mit vorberechneten Daten³ einer Verwendung von Rohdaten vorzuziehen – insbesondere weil sich die Tarifmodelle ständig ändern. Dies scheint vor dem Hintergrund, dass diese Berechnungsmodelle das Kerngeschäft der Datenlieferanten bilden, logisch. Das Data Matching im Bereich der Energiemarktdaten wurde anhand eines Preisgefälles realisiert, welches dann innerhalb der Qualitätsbewertung den Einfluss der Energiemarktdaten nachweisen konnte.

Bessere Qualität durch externe Daten

Insgesamt kann die Verwendung der vorgestellten Daten aufgrund der positiven Effekte auf die gesamte Modellqualität und der deutlichen Steigerung der Trefferquote empfohlen werden. Die externen Daten bieten überdies den Vorteil, dass sie unabhängig von der Datenbasis des Energieversorgers eine hohe Datenqualität bieten. Nichtsdestotrotz muss die Eignung des Data-Mining-Modells bei jedem Kunden individuell geprüft werden.

Durch die zielgerichtete Ansprache von Kunden lässt sich ein effektives Churn-Management installieren. Dies wird durch den optimalen Einsatz des verfügbaren Budgets ermöglicht. In Kombination mit Betrachtun-

gen aus dem Customer Lifetime Value kann damit langfristig eine profitable Kundenbasis gebildet werden, die eine weitgehend hohe Loyalität aufweisen kann.

Dazu müssen die Klassifikationsmodelle des Data-Mining in die täglichen Geschäftsprozesse eingebunden werden. Diese Empfehlung findet sich auch bei Prof. Dr. Manfred Bruhn in einer Analyse des Phänomens der Kundenabwanderung wieder [8]: „Die Kundenabwanderungsanalyse ist in der Lage, die relevanten Frühwarnindikatoren der Kundenabwanderung (...) zu identifizieren. Hieraus folgt die Notwendigkeit zum Aufbau eines Frühwarnsystems im Unternehmen. Auf der Basis identifizierter Wechselwahrscheinlichkeiten können geeignete Maßnahmen der individuellen Kundenansprache folgen, die bei konsequenter Umsetzung zu einer Senkung der Abwanderungsrate führen.“

Vom Data-Mining zur selektiven Kundenbindung

Die Kundenbindung spielt im Energiemarkt eine zentrale Rolle. Durch hohe Neukundenboni sind die Unternehmen gezwungen, Kunden im Sinne einer Ertragssicherung so lange wie möglich zu halten. Dabei stellt sich immer auch die Frage nach der Zielgruppe von Kundenbindungsmaßnahmen. Adressiert man die gesamte Kundenbasis als Zielgruppe, ist der relative Kundenvorteil bei einem gegebenen Budget sehr gering. Lässt sich hingegen die Zielgruppe einschränken, steigt der relative Kundenvorteil deutlich.

An dieser Stelle wäre es also ideal, nur tatsächlich kündigunggefährdete Verträge zu bearbeiten, da diesen Kunden dann verhältnismäßig hohe Vorteile angeboten werden können. An diesem Punkt knüpft nun der Begriff der selektiven Kundenbindung an. Wie bereits begrifflich enthalten, stellt sich hierbei die Frage nach einem Selektionskriterium. Hier sind nun die vorgestellten Data-Mining-Verfahren ein idealer Kandidat.

Diese Ergebnisse lassen sich mit einer Customer Lifetime Value (CLV)-Betrachtung kombinieren. Ziel soll sein, nicht nur Kunden anzusprechen, die mit hoher Wahrscheinlichkeit einen Vertrag kündigen, sondern zudem auch nur die „profitablen“ Kunden

zu selektieren. Dass ein Kunde mit einem hohem Verbrauch (Mehrpersonenhaushalt, usw.) profitabler ist als ein sparsamer Kunde, erscheint logisch. Dass das Alter eines Kunden eine Rolle spielen kann, ebenfalls. So ist eine junge Familie, deren Stromverbrauch bspw. aufgrund kleinerer Kinder noch steigen wird, betriebswirtschaftlicher interessanter als ein Kunde, der aufgrund seines Alters nur noch eine begrenzte Anzahl an Jahren Kunde sein wird.

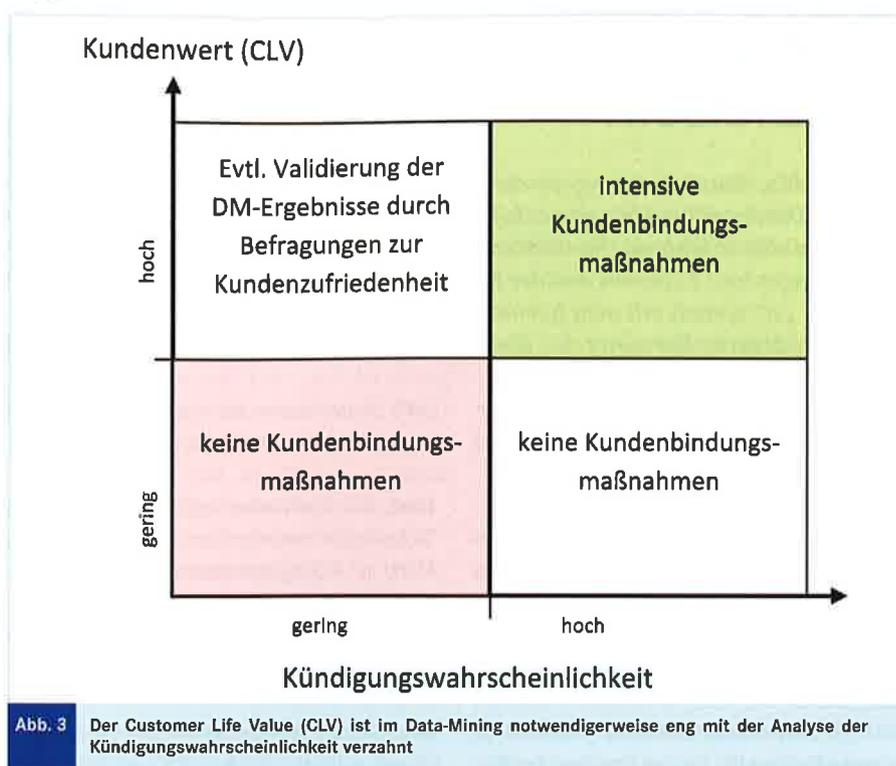
Auch wenn die getroffenen Aussagen zunächst schockierend klingen mögen, finden diese Überlegung zunehmend Einzug in eine Kundenwert-Betrachtung. In der Versicherungsbranche sind diese Ansätze in Form der Berücksichtigung von Sterbetafeln ebenfalls gängige Praxis. Der Zusammenhang der Kündigungswahrscheinlichkeit aus den Data Mining Verfahren und der CLV ist in Abb. 3 als Matrix dargestellt.

Umsetzung als IT-Tool

Die ENER:GY Softwarelösung der Wilken GmbH stellt eine integrierte Komplettlösung für EVU dar und beinhaltet Module des Finanz- und Rechnungswesens, des Controlling und Reportings, der Bau- und Auftragsabrechnung, des Energiedatenmanagements sowie das KundenInformations-Cockpit (KIC). Dabei sind insbesondere die CRM-Lösung KIC und das Energiedatenmanagement vollständig integriert.

Im Bereich des KIC steht den Kunden ein umfangreiches Kampagnenmanagement zur Verfügung. An dieser Stelle sind die Data-Mining-Funktionalitäten implementiert. So können bspw. Kunden für eine Marketingkampagne auf der Basis Ihrer Kündigungswahrscheinlichkeit selektiert werden. Der Kunde profitiert dabei auf zweifache Weise: Zum einen arbeiten im Hintergrund fundierte mathematische und statistische Verfahren in Kombination mit verschiedenen Datenverarbeitungsschritten.

Die Qualität der Prognosen kann mit bewährten und aussagekräftigen statistischen Verfahren nachgewiesen werden. Zum anderen bleibt die Funktionalität durch die volle Integration in die bestehende Softwarelösung leicht zu bedienen und überfordert den Anwender nicht. Die im Hintergrund



stehenden Verfahren müssen von diesem nicht nachvollzogen oder gar konfiguriert werden. Zusammen finden sich also ideale Voraussetzungen, das entwickelte Prognosemodell in die alltäglichen Geschäftsprozesse zu integrieren.

Data-Mining: Ein klarer Wettbewerbsvorteil

Für die erfolgreiche Einführung eines Churn-Management müssen die Klassifikationsmodelle des Data-Mining in die täglichen Geschäftsprozesse eingebunden werden. Durch die Verwendung externer Daten kann die Prognosequalität nochmals deutlich gesteigert und zugleich eine detailreichere Sicht auf die Kundenbasis geschaffen werden. Die Qualität der Modelle lässt sich anhand etablierter statistischer Verfahren nachweisen und spielt eine zentrale Rolle im Entwicklungsprozess. Insgesamt kann die proaktive und zielgenaue Ansprache der wechselgefährdeten Kunden der entscheidende Wettbewerbsvorteil im vorherrschenden Verdrängungswettbewerb sein.

Anmerkungen

[1] Die Delphi-Methode ist eine mehrstufige Befragungsmethode, die unter Experten verschiedener

Fachbereiche schriftlich durchgeführt wird. Dabei wird nach dem Eintreten bestimmter Zukunftsereignisse oder nach der Beurteilung von Entwicklungstrends gefragt.

[2] Werthschulte, S.; Holst, A.; Kübel, M.; Kielmann, J.: Zukunftserwartungen über die Entwicklung der deutschen Energiewirtschaft mit Themenschwerpunkt Netze, Kronberg im Taunus 2008.

[3] Wisotzky, P. A.: Digitale Kundenbindung. In: FH-Schriften zu Marketing und IT, Band 1, Lohmar/Köln 2001.

[4] BDEW: BDEW-Umfrage zum Verhalten der privaten Stromkunden, 2007.

[5] Lazarov, V.; Capota, M.: Churn Prediction, 2008, abrufbar unter: <http://home.in.tum.de/~lazarov/files/research/papers/churn-prediction.pdf>, gesehen am 24.9.2010.

[6] Hippner, H.; Küsters, U.; Meyer, M.; Wilde, K.: Handbuch Data Mining im Marketing, 1. Auflage, Wiesbaden 2001.

[7] Wisotzky, P. A.: Digitale Kundenbindung. In: FH-Schriften zu Marketing und IT, Band 1, Lohmar/Köln 2001.

[8] Bruhn, M.; Michalski, S.: Analyse von Kundenabwanderungen - Forschungsstand, Erklärungsansätze, Implikationen. In: Zeitschrift für betriebswirtschaftliche Forschung 55 (2003).