

## Data Mining – Energieschub für Stadtwerke



**Autorin:** Andrea Ahlemeyer-Stubbe,  
Diplom Statistikerin,  
Director Strategical Analytics  
bei der HackerAgency München GmbH  
(andrea.ahlemeyer-stubbe@hal2l.com)

Erschienen in: GWF Gas + Energie, Ausgabe 01/2017

Data Mining, Big Data, Predictive Modelling, Kundenbindung, Kündigungsprävention

Der Wettbewerb auf dem Energiemarkt stellt Stadtwerke und regionale Energieversorger in Konkurrenz mit z. T. global agierenden Unternehmen. Umso wichtiger ist es, treue Stammkunden aufzubauen, die im Idealfall durch ihre Fürsprache auch noch bei der Neukundengewinnung helfen.

Doch Kunden haben Ansprüche. Sie wollen über verschiedene Kanäle angesprochen werden – mobil, über soziale Netzwerke, per Mail. Sie erwarten schnelle Reaktionen und aktuelle, individuelle, relevante Kommunikation. Um diesen Ansprüchen gerecht zu werden, braucht es mehr als Bauchgefühl. Es braucht fundiertes, datenbasiertes Wissen zu jedem einzelnen Kunden und ein analysegestütztes Customer Relationship Management (CRM).

Wie Sie mit Data Mining in Ihrem Stadtwerk Ihre Bestandskunden, deren Bedürfnisse und deren Potenzial kennenlernen und wie Sie diese Erkenntnisse zur Neukunden-Gewinnung, zur Optimierung des Energie-Einkaufs und somit als Wettbewerbsvorteil nutzen können, erfahren Sie in diesem Artikel.

Data Mining – Boost of Energy for Public Utility Companies

Municipal utility companies and regional energy suppliers compete in the energy market with partly global companies. It is therefore all the more important to build up loyal regular customers who, in the ideal case, also help to win new customers through their advocacy.

But customers are sophisticated. They want to be addressed via various channels – via mobile, social networks, e-mail. They expect quick reactions and current, individual, relevant communication. In order to meet these requirements, it needs more than to trust in one's gut. It requires sound, data-based knowledge about each individual customer and an analysis-supported Customer Relationship Management (CRM).

In this article you will learn how to use Data Mining in your public utility company to get familiar with your existing customers, their needs and their potential, how to use these findings to gain new customers, to optimize energy purchasing and thus to gain some competitive advantages.

In Gesprächen mit Leitern von kleinen und mittelgroßen Stadtwerken oder regionalen Energieversorgern dreht es sich immer wieder um die Frage: Was können wir tun, um weiter am Energiemarkt bestehen zu können und unsere Kunden fest an uns zu binden? Wie können wir die aktuellen Herausforderungen meistern?

Liberalisierung des Energiemarktes, wachsende, auch internationale Konkurrenz, staatliche Regulierungen und Auflagen, ständig sich verändernde Preise an der Energiebörse oder bei direkten Geschäftspartnern... Und die Kunden sind heute auch keine feste Größe mehr, können sie doch so einfach wie nie zu anderen Energie-Anbietern wechseln, die scheinbar günstiger sind.

Denn Energie ist ein Low Involvement Product. Von allen gebraucht, selbstverständlich vorhanden, nur bemerkt, wenn die Versorgung ausfällt. Image und Marke? Nebensächlich. Wer Energie bezieht, spürt ja im Normalbetrieb keinen Unterschied in der Qualität. Unterschieden wird zuerst über den Preis.

Seit einiger Zeit geistern Begriffe wie Digitale Transformation und Big Data Analytics durch jede Fachtagung – aber ist das nicht nur was für die wirklich großen Unternehmen? Können sich regionale Energieversorger das überhaupt leisten?

Die Frage muss doch lauten: Wer kann es sich heute noch leisten, einen Großteil der vorhandenen Informationen nicht zu nutzen? Denn um im turbulenten Wettkampf auf dem Energiemarkt obenauf zu bleiben, braucht es vor allem fundiertes Wissen um Kundenbedürfnisse. Und dieses lässt sich nicht einfach nur per gutem Bauchgefühl generieren. Dieses Wissen liefern verlässliche Analysen der relevanten Daten aus der Datenflut, die auch Stadtwerke und Energieversorger heute generieren.

### Interne und externe Datenquellen



So liegen intern, abhängig von den vorhandenen Geschäftsbereichen, alle möglichen Informationen über die Kunden vor. Verbrauch, Rechnungen, Abnahmestellen, Abschlagszahlungen, Zahlungsverhalten, Energieart, Art und Alter der Verbrauchsanlagen,

Daten über den Zustand des Versorgungsnetzes, Service-Einsätze, Störungsarten und –häufigkeiten ...

Aus externen Quellen strömen Angaben wie aktuelle Energiepreise und Lieferantendaten. Smart-Meter-Technologien, Lastgangzähler produzieren stetig Informationen.

Viele Stadtwerke liefern Energie in Form von Strom, Gas und Wärme. Sie sind für Wasser/Abwasser zuständig und manche sind Teil des regionalen Verkehrsverbundes. Der Blick über Geschäftsbereichsgrenzen hinweg öffnet die Sicht für neue Zusammenhänge: Welche Kunden beziehen bei uns keinen Strom, aber Gas und Wärme? Können wir diese auch für den Strombezug „aus einer Hand“ gewinnen? Lohnt es sich, Nutzer des öffentlichen Nahverkehrs gezielt auf den Bezug „grüner“ Energien anzusprechen?

Unter Wahrung der gesetzlichen Auflagen kann durch die Zusammenführung der einzelnen Sparten eine große Datenbasis entstehen, die ein rundes Bild über die Bedürfnisse der Kunden bietet – eine hervorragende Grundlage für die Entwicklung von individuellen Kommunikations- und Kundenbindungsmaßnahmen.

Doch viele Daten alleine machen noch keine Big-Data-Lösung. **Daten sammeln – Daten analysieren – Daten nutzen** – nur durch diesen kontinuierlichen Kreislauf lässt sich aus den Daten wirklich Gewinn ziehen.

## 1. Sammeln

Noch nie war es so einfach und günstig wie heute, große Mengen an Daten zu sammeln, zu speichern und zu verwalten. In diesem Zusammenhang fallen immer wieder die Schlagworte Kundendatenbank, Datawarehouse und Big Data. Eine kurze Erklärung:

Eine zentrale Kundendatenbank ist Grundvoraussetzung für die Anwendung von Data Mining. In ihr sind zu jedem einzelnen Kunden (also zu Personen oder Firmen) sowohl Stammdaten (Name, Adresse, Abnahmestellen...) als auch Transaktionsdaten (Vertragsabschluss, Tarifwechsel...) sowie Kunden-Profildaten (z. B. Kundenwert) und, falls vorhanden, Lastprofile zur spezifischen Kennzeichnung und Klassifikation gespeichert.

Ein Data-Warehouse beinhaltet die Informationen aus der Kundendatenbank. Dazu ist es eine themenorientierte, integrierte, chronologisierte und persistente Sammlung von Daten, um das Management bei seinen Entscheidungsprozessen zu unterstützen. [1] Hier werden alle Datensätze für die verschiedenen Frontend-Anwendungen verwaltet.

Big Data steht für Konzepte, Methoden, Technologien, IT-Architekturen und Werkzeuge, die aus schnell sich wandelnden Informationen relevante Kenntnisse schaffen. Sammeln von anwendbaren Daten und effiziente Datenspeicherung sind nur ein Teil von Big Data. Erst intelligente Analyse-Techniken und Methoden extrahieren "versteckte" Erkenntnisse und Informationen aus riesigen Datenpools. [2]

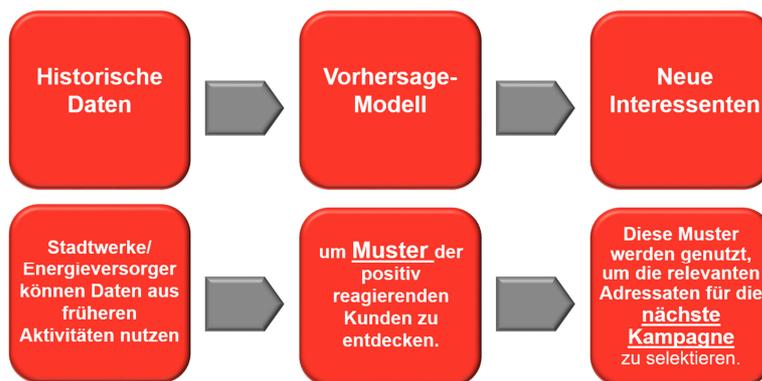
## 2. Analysieren

Unter dem Begriff Data Mining sammeln sich solche intelligenten Analysetechniken. Definiert wird Data Mining als: Entdecken und Identifizieren von interessanten, unbekanntem, unerwarteten, nicht trivialen, nützlichen, neuen, verständlichen und interpretierbaren Mustern, Strukturen und Informationen in üblicherweise großen Datenbeständen. [3]

Im Data Mining werden verschiedenste Methoden eingesetzt: Deskriptive Statistik zur Darstellung der Daten (z. B. Häufigkeitsauswertungen, Mittelwerte, Varianz) und explorative Verfahren (Erkennen von Mustern und Zusammenhängen). [4] Auch die Entwicklung von Vorhersagemodellen (Predictive Modelling, Scoring) gehört dazu, um die Wahrscheinlichkeit verschiedener Ereignisse (Kündigung, Verbrauchsspitzen, Vertragsabschluss, usw.) zu beurteilen.

Vereinfacht könnte man sagen: Daten aus der Vergangenheit werden herangezogen, um Verhalten/Reaktionen zukünftiger Interessenten vorherzusagen.

### Die Data-Mining-Lösung [5]



Die beim Data Mining eingesetzten Methoden sind nicht neu – neu ist die Menge der anfallenden Daten und die Rechnerleistung, die heute verfügbar ist, um auf diesen riesigen Datenbeständen Algorithmen in hoher Geschwindigkeit berechnen zu lassen.

### 2.1 Data Mining – wie geht das?

Beim Data Mining unterscheidet man zwei grundsätzliche Vorgehensweisen:

- Überprüfung von Hypothesen über Muster innerhalb der Daten
- Entdecken von bisher unbekanntem Mustern oder Regeln in den Daten

Während für die erste Vorgehensweise vorab eine entsprechende Hypothese entwickelt werden muss, versucht man im zweiten Fall neue Muster in den Daten zu finden. [6]

Ein Beispiel für die Validierung von Hypothesen: Ein Stadtwerke-Betreiber vermutet: „Nutzer des Verkehrsverbundes wollen eher auf die Versorgung mit alternativen Energien umsteigen als Kunden, die den Verkehrsverbund nicht nutzen.“ Durch Analyse der Unterschiede hinsichtlich der bezogenen Energieart von Verkehrsverbund-Kunden und Nicht-Verkehrsverbund-Kunden kann diese Hypothese bestätigt oder widerlegt werden. Wird sie bestätigt, kann der Energieversorger verstärkt die Zielgruppe der Verkehrsverbund-Nutzer mit Angeboten zu „grüner“ Energie ansprechen und verringert dadurch Streuverluste.

Um die Erkennung neuer, unbekannter Zusammenhänge in Daten handelt es sich, wenn neue logische Regeln aus der Kombination mehrerer unterschiedlicher Merkmale ermittelt werden. Ergibt sich zum Beispiel bei der Analyse der Bestandskundendaten, dass 80% der Kunden, die von einem anderen Anbieter zu den Stadtwerken gewechselt sind, vor dem

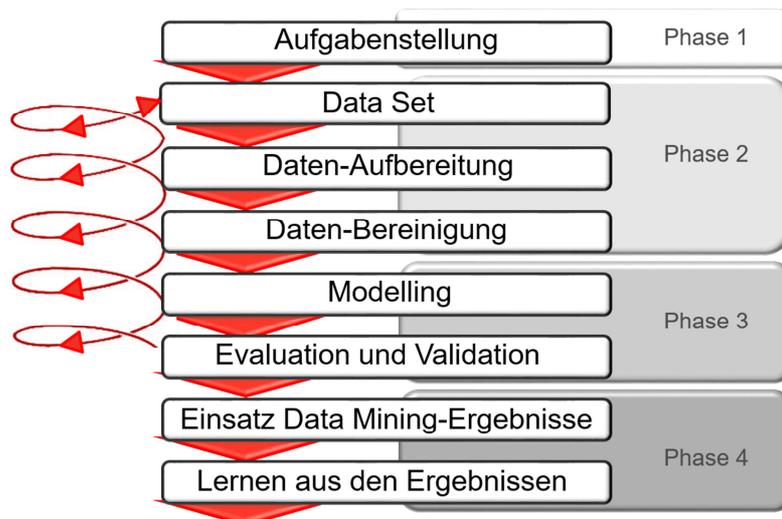
Wechsel den kostenlosen Energieberatungs-Service der Stadtwerke in Anspruch genommen haben, hat dieses Ergebnis großen Einfluss auf strategische Entscheidungen.

Denn: Würde man diesen – für sich genommen defizitären - Service streichen, bestünde die Gefahr, die Chance zur Neukundengewinnung bzw. Rückgewinnung abgewanderter Kunden zu verringern. Der Verlust könnte dabei so groß sein, dass er nicht durch die Einsparung von Mitarbeiter-Ressourcen aufgewogen würde. Wie das Risiko aussieht, kann mit Hilfe der Analyse besser abgeschätzt werden.

Auf der anderen Seite kann das Ergebnis auch dazu führen, dass der Energieberatungs-Service gezielt beworben wird – wir sind vor Ort, wir beraten Sie fundiert, wir sind für Sie da – und so lokale Kunden anderer Energieversorger zum Wechsel zu „ihrem“ lokalen Energieversorger/Stadtwerk zu bewegen.

Das nachfolgende Beispiel einer Kündiger-Analyse (zur Vereinfachung mit Fokus auf den Zeitraum vor der Kündigung) verdeutlicht die Phasen, die ein Data-Mining-Projekt durchläuft.

## 2.2 Der Data-Mining-Prozess [5]



Die aktuelle Lage: Einem lokalen Energieversorger kündigen stetig Kunden. Data Mining soll ihn dabei unterstützen, wertvolle Bestandskunden von der Abwanderung abzuhalten.

### Phase 1: Aufgabenstellung

Sehr wichtig: die sorgfältige Eingrenzung der Fragestellung, die die mit Hilfe von Data Mining beantwortet werden soll. Dazu braucht es Wissen um die Geschäftsprozesse, die den zu analysierenden Daten zu Grunde liegen sollen. Denn egal, ob nach noch unbekanntem Mustern in den Daten gesucht wird oder ob Hypothesen überprüft werden: Man muss wissen, wo und wie das Data-Mining-Tool suchen soll.

Welche unserer Kunden sind abwanderungsgefährdet? Betrachtet man den Charakter dieser Fragestellung, wird schnell klar, dass sich die Antwort nicht aus einem einzelnen Datenfeld oder Kundenmerkmal ergibt, sondern in der richtigen Kombination

unterschiedlicher Kundeninformationen entsteht. Mit Data Mining lassen sich solche Informationen systematisch verknüpfen.

Das Ziel heißt in diesem Fall: Abwanderungsprävention. In den Daten sollte also nach Business-Regeln gesucht werden. Was sind die Charakteristiken der Kunden, die in der Vergangenheit zu einem anderen Anbieter abgewandert sind? Wenn diese neu zu entdeckenden Merkmale mit den Daten der Bestandskunden abgeglichen werden, lässt sich vorhersagen, welche Kunden eine hohe Wahrscheinlichkeit haben, in nächster Zeit ebenfalls zu einem anderen Anbieter zu wechseln.

## **Phase 2: Datensätze auswählen, aufbereiten und bereinigen**

Aus allen zu bereits abgewanderten Kunden vorliegenden Informationen werden die für die Fragestellung relevanten Daten extrahiert: Geschäftskunde oder Privatkunde, Alter, Geschlecht, Grund der Kündigung, Dauer der Kundenbeziehung, vor Kündigung bezogene Produkte (Strom, Gas, Wärme...), Zahlungsverhalten, Verbrauch, zugehörige Abnahmestellen, Störfälle, ... Diese Datensätze werden untersucht, wenn nötig bereinigt, aufbereitet, aggregiert und transformiert und für die Analyse bereitgestellt.

## **Phase 3: Modell erstellen und optimieren, Evaluierung und Validierung der Analyse-Ergebnisse**

Bei der Modellbildung, einem wesentlichen Bestandteil des Data Mining, sucht man Algorithmen, mit denen sich zukünftige Ereignisse bezogen auf die Aufgabenstellung vorhersagen lassen. Die gebräuchlichsten Methoden sind dabei Regression, Entscheidungsbäume und Neuronale Netze. Mit Hilfe von Data-Mining- oder statistischer Software werden diese Modelle von Experten erstellt.

Ja, Vorhersagemodelle sind nie 100%ig exakt. Es gibt immer eine gewisse Fehlerquote, es besteht das Risiko von Fehlprognosen. Doch die Praxis zeigt: Der Vorteil der richtigen Vorhersagen überwiegt.

Modelle sind wie Stadtpläne: Diese zeigen die Straßenverläufe, aber keine architektonischen Details wie besonders schöne Fassadengestaltungen. Wenn man weiß, wohin man will, kann man sich mit dem Stadtplan einen Weg aussuchen und findet sogar noch Alternativen. So liefern auch die Vorhersagemodelle die wesentlichen, für die Zielerreichung notwendigen Informationen.

Das Modell ist erstellt. Ein Testlauf über Teilmengen der abgewanderten Kunden überprüft dieses Modell und bringt die wichtigsten Merkmale zu Tage. Durch Geschäftswissen und Erfahrung werden diese validiert und beurteilt: Es ist wahrscheinlich nicht relevant, dass viele Kündiger ihren Vertrag an einem Dienstag abgeschlossen haben – aber dass in einem bestimmten Zeitraum nach aufgetretenen Störfällen je nach Art und Weise der Behebung die Wechselbereitschaft größer wird, ist eine wichtige Regel, die in die Kündiger-typischen Merkmale aufgenommen werden muss.

Als Faustregel kann gelten: Wenn sich ein Vorhersageergebnis nahtlos in den Erfahrungshorizont des Stadtwerke-Fachmanns einpasst und er das Gefühl hat, er hätte da selbst draufkommen können, dann geht das Modell den richtigen Weg.

#### **Phase 4: Ergebnisse anwenden, Erfolg messen**

Nach Anwendung der Algorithmen auf alle Bestandskunden könnte ein Ergebnis die Auflistung von 16 % aller aktiven Kunden sein, die eine sehr hohe Wahrscheinlichkeit aufweisen, abzuwandern.

Die Vorhersage erlaubt es dem Energieversorger zu agieren statt erst auf eine vollzogene Kündigung zu reagieren. Jetzt kann die Zeit genutzt werden, um rechtzeitig aktiv zu werden: Einerseits können die Erkenntnisse über Zusammenhänge dazu genutzt werden, um bestehende Missstände zu beheben. Z. B. daran zu arbeiten, dass Störungen innerhalb von 24 Stunden behoben werden. Andererseits heißt es, herauszufinden, welche der abwanderungsgefährdeten Kunden die wertvollsten sind, für welche sich Präventionsmaßnahmen lohnen und wie diese gestaltet werden können.

Um den Erfolg dieser Maßnahmen zu messen, können die „Abwanderungsgefährdeten“ in zwei Gruppen aufgeteilt werden. An eine Gruppe richten sich die Präventionsmaßnahmen, die andere wird behandelt wie alle anderen Kunden. So lassen sich nach einem festgelegten Zeitraum die tatsächlichen Kündigerquoten der beiden Gruppen vergleichen.

### **3. Nutzen**

Die größte Datenmenge, die besten Analysen, die aussagekräftigsten Erkenntnisse können erst etwas bewirken, wenn sie auch in konkrete Taten und Maßnahmen umgesetzt werden. Um bei dem Beispiel des Stadtplans zu bleiben: Wir sehen verschiedene mögliche Wege, aber um ans Ziel zu kommen, müssen wir uns in Bewegung setzen.

So können die entdeckten kündigungsgefährdeten Kunden ein freundliches Schreiben erhalten, das ihnen für ihre Treue dankt. Besonders wertvollen unter Ihnen könnte ein Treue-Angebot unterbreitet werden oder sie werden zu einem besonderen Event eingeladen.

Erfolgsmessungen, Erfahrungen aus den Kampagnen fließen wiederum als Daten in den Kreislauf ein. So bleibt Data Mining keine Einbahnstraße, sondern Teil eines lernenden, sich entwickelnden Systems.

### **4. Anwendungsgebiete für Stadtwerke und lokale Energieversorger**

Nicht immer muss die große Analyse-Keule zum Einsatz kommen. Häufig reichen schon kleine Analysen, regelmäßiges Reporting bis hin zur Anwendung von Geschäftsregeln. Wird zum Beispiel ein neues Baugebiet in der Region ausgewiesen, braucht es keine tiefeschürfende Untersuchung um zu wissen, dass die Bauherren höchstwahrscheinlich einen neuen Energieversorger und Beratung brauchen. Doch es gibt Fragen, die sich zuverlässig nur durch präzise Analysen beantworten lassen – wie beschrieben zum Beispiel was Kündigungsprävention betrifft.

Data Mining unterstützt mit wertvollen Erkenntnissen die Zukunftsfähigkeit von Stadtwerken und lokalen Energieversorgern, indem es neuen Schwung in Kundenbeziehungen bringt. Wer sind unsere Kunden? Welche Bedürfnisse haben sie? Auf welchem Weg möchten sie Informationen erhalten – per Brief, per Mail, mobil? Wie zufrieden ist jeder einzelne mit

Preisen, Service, Beratung, Reaktion bei Störungen, Transparenz der Verbrauchsabrechnung?

Zur Gewinnung von Neukunden lassen sich via Data Mining Erkenntnisse aus Analysen der Bestandskunden auf einen erweiterten Kreis von Personen und Firmen übertragen. So können darin diejenigen identifiziert werden, die zu Zielgruppen des eigenen Unternehmens gehören. Oder es können gleich ganz neue Zielgruppen gefunden werden. Gibt es Bestandskunden mit Eigenschaften, die sie zu Multiplikatoren machen, deren Fürsprache neue Interessenten anziehen könnte?

Sollen neue Serviceleistungen und/oder neue Produkte wie Biogas oder alternative Energien platziert werden? Gibt es Leistungen außerhalb des regulären Portfolios, die Kunden anziehen und binden können (z. B. soziales Engagement in Vereinen und regionalen Einrichtungen)? Data Mining hilft, Wirkung, Bedarfe und Preisakzeptanz zu prognostizieren.

Auch beim Energieeinkauf und der Tarifgestaltung kann Data Mining für den notwendigen Wettbewerbsvorteil sorgen. In welche Verbrauchssegmente lassen sich unsere Kunden einteilen? Welche Kunden-Zu- und -Abwanderung ist zu erwarten? Zu welcher Zeit (Uhrzeit, Wochentag, Woche, Monat) finden sich bei welchen Segmenten die Verbrauchsspitzen? Zu welcher Zeit (Uhrzeit, Wochentag, Woche, Monat) steht viel Energie zur Verfügung (ggf. selbst produziert – Wind, Sonne, Biogas, Blockheizkraftwerke)?

Vielfach reicht es, solche einfachen Fragen zu beantworten. Wirklichen Mehrwert bringt aber die Verknüpfung mehrerer Fragen: Mit wie vielen Kündigern und mit wie vielen Neukunden können wir verlässlich im nächsten Beschaffungszeitraum rechnen? Wie sehen deren Nutzungsprofile aus? Was bedeutet das für die Prognose der Bedarfe, für die wir jetzt die Energiekontingente beschaffen müssen?

## **5. Fazit:**

Das Sammeln und Archivieren von Transaktionsdaten sind seit Jahren auch bei Stadtwerken und regionalen Energieversorgern selbstverständlich. Und nach und nach wird damit begonnen, diese Daten in zentralen Datenbanken zusammenzufassen und zu nutzen. Mit Hilfe von Tools bzw. statistischen Software-Paketen lassen sich einige Schritte des Data Mining heute schnell und bequem durchführen. Die technischen Voraussetzungen Data Mining zu nutzen sind also vorhanden.

In jedem Stadtwerk, bei jedem regionalen Energieversorger arbeiten gut ausgebildete, innovative, teamfähige Leute mit dem entsprechenden Branchenwissen, fundierten Kenntnissen zu lokalen Gegebenheiten und einem guten Maß an Erfahrung, das für das Stellen der richtigen Fragen, für die Überprüfung der Analyseergebnisse und natürlich für deren Umsetzung unabdingbar ist. Somit steht auch der nötigen Verzahnung zwischen Analytikern und Praktikern nichts im Wege.

Bei klaren Zielsetzungen, der richtigen Datenbasis, flexibler Modellierung und schneller Anwendung der Analyseergebnisse liefert Data Mining Ergebnisse, die verständlich, zielführend und umsetzbar sind.

Deshalb ist Data Mining auch für Stadtwerke und regionale Energieversorger heute eine unverzichtbare Energiequelle fürs Business.

## 6. Literaturhinweise

[1] Inmon, William H.: Building the Data Warehouse. John Wiley & Sons, 1996, ISBN 978-0-472-124161-7, S. 33

[2] Stephan Horvath: Big Data: Fuel for „relevant Marketing“, 12 ahead, 26.07.2013, <http://www.12ahead.com/big-data-fuel-relevant-marketing>

[3] Frawley, William J. und Piatetsky-Shapiro, Gregory und Matheus, Christopher J.: Knowledge Discovery in Databases: An Overview. AI Magazine 13(3): 57-70 (1992)

[4] Tsipstis Konstantinos und Choraniopoulos, Antonios: Data Mining Techniques in CRM. John Wiley & Sons (2009)

[5] Coleman, Shirley und Ahlemeyer-Stubbe, Andrea: A Practical Guide to Data Mining for Business and Industry. John Wiley & Sons (2014)

[6] Ahlemeyer-Stubbe, Andrea: Data Mining: Den Kunden kennenlernen. Acquisa Juni 2000, S. 22-24.