

Case Study

Gasmengenprognose - Ein adaptives Gasmengen-Prognoseverfahren

Key facts

Abweichungen in der Prognose des Gasverbrauchs ziehen Ausgleichsenergiekosten nach sich. Da sich Umweltbedingungen und das Verbraucherverhalten ändern, ist ein adaptives Prognosesystem die Grundlage um die Ausgleichsenergiekosten zu senken. Die Genauigkeit der Gasmengenprognose und damit die Höhe der Ausgleichsenergiekosten kann so im Gegensatz zu herkömmlichen Verfahren stark gesenkt werden.

Ausgangssituation - Die Rolle der Gasmengenprognose

Die tägliche Gasmengenprognose ist die Grundlage für die Nominierung von Gasmengen. Die Prognose der zu liefernden Gasmengen entspricht selten genau dem eigentlichen Verbrauch der Endkunden. Durch die täglich entstehenden Differenzen zwischen den eingespeisten und den tatsächlich verbrauchten Gasmengen entstehen Kosten für Ausgleichsenergie. Die Höhe dieser Kosten ist direkt abhängig von der Höhe der Mengenabweichung und damit von der Genauigkeit der Prognose. Um Mengenabweichungen und damit Ausgleichsenergiekosten so gering wie möglich zu halten, sollte eine Prognose eine hohe Präzision aufweisen. Die Anpassung eines Prognosesystems an sich verändernde Umweltbedingungen, die den Gasverbrauch beeinflussen, ist dazu von entscheidender Bedeutung. Diese Veränderungen können unter anderem veränderte Rahmenbedingungen wie Feiertage oder geänderte klimatische Verhältnisse sein, aber auch Änderungen im Verbraucherverhalten sind möglich. Um Veränderungen der Randbedingungen und des Konsumentenverhaltens zeitnah zu erfassen, ist es unabdingbar, die Prognoseverfahren adaptiv zu implementieren.

Lösung

Das im Folgenden vorgestellte Prognosesystem reagiert selbstlernend auf veränderte Rahmenbedingungen, zum anderen besteht das System aus einer Kombination von mehreren verschiedenen Prognoseverfahren. Das selbstlernende System hat dabei den Vorteil, dass sich die Parameter automatisch an Veränderungen exogener Einflussgrößen anpassen und damit das Verfahren auf neu gesammelte Erkenntnisse aus der Historie reagiert. Die Kombination verschiedener Verfahren macht es möglich, dass sich das System besser auf unterschiedliche Datenstrukturen im Zeitablauf einstellen und damit die Prognosegüte über den gesamten Zeitraum verbessern und stabilisieren kann. Durch die dynamische Mustererkennung in der Vergangenheit kann das System dann optimal auf Veränderungen in den Daten reagieren (z.B. Änderungen des Verbraucherverhaltens im Sommer) und das bestmögliche Verfahren ermitteln. Auf diese Weise passt sich das System immer wieder neu den veränderten Umweltbedingungen bzw. dem Kundenverhalten an und sichert so langfristig die Prognosequalität.

Ablauf des Prognosealgorithmus

Um den Gasverbrauch des Folgetages zu prognostizieren, durchläuft der Algorithmus die folgenden Schritte. Im ersten Schritt findet ein Preprocessing der Daten statt, in dem vor allem fehlende Werte und Ausreißer in den Daten behandelt werden. Im zweiten Schritt werden die Datensegmente, welche zur Prognose verwendet werden, ausgewählt. Dies geschieht auf Basis einer partiellen Korrelationsanalyse, anhand derer Kovariaten und die Abschnitte der Zeitreihe, die zum Anlernen des Algorithmus besonders geeignet sind, ausgesucht werden. Im dritten Schritt werden die in Schritt II ausgewählten Datensegmente und Kovariaten genutzt, um eine Prognose zu erstellen. Dabei werden mehrere Prognoseverfahren gleichzeitig verwendet (darunter ARIMA, Lineare Regression, Kalman-Filter, Ridge Regression, etc.). In Schritt IV werden die Datensegmente und

Kovariaten entsprechend des jeweilig günstigsten Prognoseverfahrens in Klassen eingeteilt. Hierbei können in Abhängigkeit der Kundenbedarfe unterschiedliche Fehlermaße zur Messung der Prognosegüte herangezogen werden, die als Komponenten in die Definition einer Kostenfunktion eingehen. Durch die Minimierung der Kostenfunktion wird das jeweilig günstigste Prognoseverfahren festgelegt.

Das Verfahren wurde bei einem Serviceunternehmen, das vier Energieversorger mit einem Kundenstamm von insgesamt ca. 200.000 Kunden im Energiedatenmanagement betreut, zur Prognose der Restlast eingesetzt. Das untersuchte Kundenportfolio umfasst ca. 16000 Kunden. Ziel war die Verbesserung der Prognosequalität. Diese lag bisher bei einer mittleren absoluten Abweichung zwischen prognostizierter und gemessener Restlast von 23.2% Prozent bzw. einer mittleren relativen Abweichung von 5.2% für das Gesamtjahr. Da die Ausgleichsenergiekosten bei den Energieversorgern dadurch hoch waren, wurde ein stochastisches Prognoseverfahren eingesetzt, um die Ausgleichsenergiekosten zu senken.

Daten – Input

Um die Analyse und Prognose des Gasverbrauchs zu gewährleisten, musste sichergestellt werden, dass die notwendigen Daten als Zeitreihen verfügbar sind und Datenlücken geschlossen werden. Zur Prognose werden einerseits die Kundenlastgänge und die Einspeisungen benötigt. Des Weiteren werden externe Einflussgrößen wie Wochentage, Feiertage sowie die Temperatur benötigt. Historische Wetterdaten sowie Prognosen wurden im Fallbeispiel vom Energieversorger bereitgestellt und können durch private und staatliche Dienstleister bezogen werden.

Ergebnisse

Die Ergebnisse des Backtests im Zeitraum vom 1.1.2012 bis zum 31.3.2012 sind in Abbildung 1 dargestellt. Der Ausschnitt aus dem Winterhalbjahr wurde gewählt, um die Prognosegüte in einem durch hohen Energieverbrauch gekennzeichneten Zeitraum zu illustrieren. Hier ist eine genaue Prognose besonders wichtig. Um die Prognosegüte zu messen, wurden zwei Fehlermaße verwendet. Zum einen der absolute Fehler, der die mittlere absolute Abweichung des prognostizierten vom gemessenen Wert angibt. Je kleiner der absolute Fehler ist, desto besser spiegelt die Prognose an jedem einzelnen Datenpunkt die Daten wieder. Zum anderen wurde der relative Fehler berechnet, der den Quotienten der Summen aus prognostiziertem und tatsächlichem

Jahr: 2012	Jan	Feb	März	April	Mai	Jun	Jul	Aug	Sept	Okt	Nov	Dez	durchschnittlicher Fehler für ganz 2012
Relativer Fehler (%)	-0.4	-0.44	0.8	0.7	0.4	3.16	-1.08	-1.51	-0.68	-1.41	-0.57	-0.01	-0.2
Absoluter Fehler (%)	3.19	5.88	7.12	8.05	14.91	11.19	13.47	16.65	11.28	5.91	4.29	4.7	8.9

Tabelle 1 Relativer Fehler (ME) und Absolute Fehler (MAPE) pro Monat sowie für das gesamte Jahr 2012

gemessenem Wert angibt. Dieser Fehler saldiert die Über- und Unterschätzungen über einen Zeitraum und kann zur Bestimmung der Ausgleichsenergiemengen verwendet werden. Je kleiner der relative Fehler ist, desto kleiner ist der Unterschied zwischen prognostiziertem und tatsächlichem Wert über eine bestimmte Zeitspanne. Über das gesamte Jahr 2012 zeigen sich ein absoluter Fehler von 8.9 % und ein relativer Fehler von -0.2 %.




Abbildung 1 Restlast und Prognose für den Zeitraum 1.1.2012 - 31.3.2012

Fazit

Durch die Anwendung des vorgestellten Prognosesystems konnte die Abweichung des prognostizierten Wertes von der tatsächlich gemessenen Restlast deutlich, von 23,2% auf 8,9% beim absoluten und von 5,2% auf -0,2% beim relativen Fehler, gesenkt werden. Da das Kundenportfolio des untersuchten Service-Unternehmens heterogen ist und der Kundenkreis aus vier Stadtwerken zusammensetzt, ist davon auszugehen, dass die Ergebnisse auf andere Energieversorger übertragbar sind. Die Kosten für den Aufbau eines solchen Systems durch einen externen Dienstleister amortisieren sich durch die Einsparungen der Ausgleichsenergiekosten im ersten Jahr. Bezüglich des bisher vom Unternehmen verwendeten Prognoseverfahrens, der SLP der TU München, wurde festgestellt, dass das Verfahren nicht mehr die benötigte Prognosegenauigkeit aufweist. Die Parameter der SLP-Profile müssen angepasst werden. Zum Nachschärfen und damit zur Verbesserung der Prognosegüte kann dabei ein auf Regressionsverfahren basierendes System dienlich sein. Da die Formel der TU München auf der deterministischen Festlegung eines Verbrauchsprofils beruht, können Regressionsverfahren stochastische Schwankungen im Verbrauch besser ausgleichen als die TU München Formel. Die Ergebnisse der SLP-Prognose sind jedoch als Kovariate für die stochastische Prognose wertvoll. Durch die Kombination der TU München Formel und dem hier vorgestellten Verfahren kann eine optimale Prognosegüte erreicht werden. Das vorgestellte Verfahren kann daher sowohl zum Nachschärfen bestehender Verfahren als auch eigenständig zum Einsatz kommen.