

Stefan Klaiber*, Simon Waczowicz, Irina Konotop, Dirk Westermann, Ralf Mikut und Peter Bretschneider

Prognose für preisbeeinflusstes Verbrauchsverhalten

Forecast of price elastic load behavior

Zusammenfassung: Durch die Beeinflussung des elektrischen Verbrauchs mittels Preiszeitreihen (Demand Response) können zusätzliche Flexibilitätspotentiale für die Energieversorgung erschlossen werden. Durch die Einführung von Demand Response ergeben sich jedoch neue Anforderungen an die Lastprognose. Dieser Beitrag befasst sich mit der Modellierung von preisbeeinflusstem Verbrauchsverhalten (PVV) und stellt einen neuen Prognoseansatz vor.

Schlüsselwörter: Demand Response, Zeitreihenprognose, Verbraucherverhalten.

Abstract: By influencing the electrical consumption by means of price time series (demand response), additional flexibility potentials can be developed for the power supply. New requirements arise for the load forecast by introducing demand response. This paper deals with the modeling of price elastic load behavior and introduces a new approach to forecasting.

Keywords: Demand response, time series forecast, consumer behavior.

***Korrespondenzautor:** Stefan Klaiber, Institutsteil Angewandte Systemtechnik (AST) des Fraunhofer IOSB, Am Vogelherd 50, 98693 Ilmenau, E-Mail: stefan.klaiber@iosb-ast.fraunhofer.de
Peter Bretschneider: Institutsteil Angewandte Systemtechnik (AST) des Fraunhofer IOSB, Am Vogelherd 50, 98693 Ilmenau
Simon Waczowicz, Ralf Mikut: Institut für Angewandte Informatik (IAI), Karlsruher Institut für Technologie (KIT), Hermann-von-Helmholtz-Platz 1, 76344 Eggenstein-Leopoldshafen
Irina Konotop, Dirk Westermann: Fachgebiet Elektrische Energieversorgung, Technische Universität Ilmenau, Gustav-Kirchhoff-Straße 1, 98684 Ilmenau

1 Einleitung

In der Energieversorgung spielen genaue Lastprognosen eine wichtige Rolle für die optimale Planung und Betriebsführung des Energie- und Ressourceneinsatzes. Eine Maßnahme zur Erschließung neuer Flexibilitätspotentiale für die Energieversorgung ist das Demand Side Management (DSM) [1], bei dem das Verbrauchsverhalten mittels Anreiz- und/oder Steuersignalen beeinflusst wird. Mit der Beeinflussung des Verbraucherverhaltens durch DSM werden typische Verbrauchsmuster verändert [2]. Die etablierten Methoden zur Vorhersage des elektrischen Verbrauchs berücksichtigen diesen Einfluss und die damit verbundenen unterschiedlichen Auswirkungen auf den inneren Systemzustand i. d. R. nicht, so dass mit einer Verschlechterung der Prognosegüte und somit mit einer größeren Unsicherheit bei der Verbrauchsprognose und den darauf aufbauenden Folgeprozessen zu rechnen ist [3]. Somit werden neue Prognosemethoden benötigt, um die komplexen autoregressiven und exogenen Zusammenhänge des Verbraucherverhaltens mit den beeinflussenden Preiszeitreihen (Demand Response) abbilden zu können.

Im vorliegenden Beitrag wird eine Methode zur Prognose von preisbeeinflusstem Verbrauchsverhalten (PVV) vorgestellt, welche gegenüber dem Einsatz etablierter Methoden zur Lastprognose signifikante Vorteile aufweist. Dazu werden im Abschnitt 2 zunächst Modellierungsansätze für preiselastisches Verbrauchsverhalten eingeführt. Im Abschnitt 3 werden die sich aufgrund des preiselastischen Verbrauchsverhaltens ergebenden neuen Anforderungen an die Verbrauchsvorhersage erarbeitet und ein dafür geeigneter neuer Modellansatz wird vorgestellt. Die Abschnitte 4 und 5 zeigen die Modellvalidierung und fassen die Untersuchungsergebnisse zusammen.

2 Preisbeeinflusstes Verbrauchsverhalten

Ist das Verbrauchsverhalten durch Preisanreize beeinflussbar, dann stellt sich als Reaktion auf eine Preisänderung Δp eine Laständerung Δy ein. Wie stark Δy dabei ausgeprägt ist, hängt von der Preiselastizität ζ ab. Die Wirtschaftstheorie besagt, dass, wenn alle sonstigen Faktoren konstant gehalten werden, ein steigender Energiepreis einen sinkenden Energiebedarf bewirkt. Dabei ist ζ ein Maß für die Sensibilität der Verbraucher, auf Preisänderungen zu reagieren. Sie hat typischer Weise ein negatives Vorzeichen und ist laut Gleichung (1) die prozentuale Änderung des Verbrauchs y im Verhältnis zur prozentualen Änderung des Preises p [4]:

$$\zeta = \frac{\Delta y/y}{\Delta p/p}. \quad (1)$$

Für die mathematische Beschreibung des Verbrauchsverhaltens mit anreizbasierter Verbrauchsbeeinflussung finden sich in der Literatur zahlreiche Modellansätze, welche sehr häufig den Zusammenhang zu ζ berücksichtigen. Die Verbraucherreaktion auf Preiseinflüsse wird in Eigen-Preiselastizität ζ_{ii} und Kreuz-Preiselastizität ζ_{ij} unterteilt [4–6] (mit: y_i – Initialverbrauch, y_{ref} – Referenzverbrauch, p_i – Initialpreis, p_{ref} – Referenzpreis, i – Zeitintervall und j – Zeitintervall). Während die Eigen-Preiselastizität entsprechend Gleichung (2) eine Verbrauchsänderung als unmittelbare Folge einer Preisänderung im selben Zeitintervall i abbildet, beschreibt die Kreuz-Preiselastizität die zeitliche Verschiebung des Verbrauchs (z. B. Verschiebung des Verbrauchs von Hoch- zu Niedrigpreiszeitabschnitten):

$$\zeta_{ii} = \frac{\Delta y_i/y_{ref}}{\Delta p_i/p_{ref}} \quad \text{und} \quad \zeta_{ij} = \frac{\Delta y_i/y_{ref}}{\Delta p_j/p_{ref}}. \quad (2)$$

Der beeinflussbare Anteil des Verbrauchs und somit ζ ist dabei von verschiedenen Faktoren abhängig. Ein wesentlicher Einflussfaktor ist der Zeitpunkt. Das Beeinflussungspotential einer Verbraucherlast kann aufgrund von individuellem, uhrzeitabhängigem oder saisonalem Verbrauchsverhalten der Haushalte und der Industrie variieren. Neben der Uhrzeit kann ζ auch von repräsentativen Typtagen abhängig sein, da sich das Verbrauchsverhalten häufig an Werktagen, Feiertagen oder Wochenenden unterscheidet. In [7] wird ζ zeitvariabel beispielsweise in Abhängigkeit von Monat, Tag, Stunde (Uhrzeit), Typtag und saisonalen Einflüssen als Maß für die Änderung der Nachfrage als Reaktion auf eine Preisänderung modelliert.

Der Zeithorizont, für den die Preise im Vorfeld festgelegt und den Verbrauchern bekannt sind, wirkt sich z. B. direkt auf die Planbarkeit der Verbraucher aus, auf Preisänderungen durch eine entsprechende Verbrauchsänderung zu reagieren. Des Weiteren ist die Historie von beeinflussten Verbrauchszeitreihen von Bedeutung, da daraus abgeleitet werden kann, wie groß der Anteil des bereits genutzten Beeinflussungspotentials ist und somit aktuell nicht zur Verfügung steht. Dazu wird in [8] ein Konzept vorgestellt, bei dem das Verbraucherverhalten von Haushaltskunden als virtueller Speicher beschrieben wird. Neben der Modellierung als virtueller Speicher [8] oder als Regressionsmodell [9] wird das Verbraucherverhalten in [7] als Optimierungsmodell und in [1] mit Hilfe von Monte-Carlo-Simulationen abgebildet. Dabei werden die für die Modellierung benötigten Parameter beispielsweise aus einem sozioökonomischen Modell oder einem Feldversuch eines Pilotprojektes gewonnen.

Durch variable Stromtarife, bei denen die Preisinformationen den Verbrauchern mit einer entsprechenden Vorlaufzeit vorliegen, sind die reaktionsauslösenden Preisereignisse vorab bekannt. Die Reaktion der Verbraucher ist nicht nur unmittelbar auf ein entsprechendes Preisereignis zu erwarten. Vielmehr kann die Reaktion bei einer Lastverschiebung dynamisch a priori oder a posteriori zeitversetzt auftreten (Kreuz-Preiselastizität). Für einen preiselastischen Verbrauch über 24 Stunden mit einer Abtastzeit von 15 Minuten können verschiedene ζ in einer 96×96 Matrix \mathbf{Z} dargestellt werden [4, 6, 11] (vgl. Gleichung (3)). Dabei beschreiben die Diagonalelemente der Matrix die Eigen-Preiselastizitäten ζ_{ii} und die Nichtdiagonalelemente die Kreuz-Preiselastizitäten ζ_{ij} :

$$\mathbf{Z} = \begin{bmatrix} \zeta_{1,1} & \cdots & \zeta_{1,96} \\ \cdots & \cdots & \cdots \\ \zeta_{96,1} & \cdots & \zeta_{96,96} \end{bmatrix}. \quad (3)$$

Die Spalte j der Matrix \mathbf{Z} beschreibt, wie eine Preisänderung in dem einzelnen Zeitintervall j den Verbrauch in allen andern Zeitintervallen beeinflusst. Sind alle Elemente, die ungleich Null sind, über der Diagonalen, dann entspricht die Verbraucherreaktion auf hohe Preise einer Lastverschiebung vor das verursachende Preisereignis. Sind alle Elemente, die ungleich Null sind, unterhalb der Diagonalen, dann wird Leistung in einen Zeitbereich nach dem Preisereignis verschoben. Ist das Flexibilitätspotential begrenzt, dann sind die Elemente, die ungleich Null sind, um die Diagonale zu den Zeitintervallen mit den niedrigsten Preisen angeordnet [11]. Der Planungshorizont hat ebenfalls Einfluss die Besetzung der Matrix \mathbf{Z} . Sind die Preise im Vorfeld nicht bekannt, dann wirkt sich das auf die Elemente oberhalb der Diagonalen aus. Die Lastände-

ung über dem Zeitintervall i als Resultat der Abweichung zum Initialpreis ergibt sich aus Gleichung (4):

$$\Delta y_i = \sum_{j=1}^{96} \zeta_{ij} \cdot \left(\frac{\Delta p_j}{p_{ref}} \right) \cdot \zeta_{ref}. \quad (4)$$

3 Modellbeschreibung

3.1 Anforderungen an die Prognosemethode

Beim DSM ist die einflussnehmende Preiszeitreihe $p[k]$ das Ergebnis eines komplexen Planungsprozesses und wird mittels eines Preisbildungsmechanismus erzeugt. Dabei soll der Preis die Last beeinflussen, um z. B. bestehenden Netzrestriktionen zu genügen, Marktkriterien gerecht zu werden oder auch die Last der aktuellen Erzeugung anzupassen [1, 5, 11, 12]. Es wird eine Prognosemethode benötigt, welche die komplexen Zusammenhänge des PVV abbilden kann. Die Prognosemethode und die zugrundeliegenden Datenanalyseverfahren können dabei nur auf historische Zeitreihen preisbeeinflusster Verbraucher zurückgreifen, da die unbeeinflusste Komponente nicht separat messbar ist. Die Prognosemethode soll neben der beeinflussten Verbrauchszeitreihe auch den unbeeinflussten Verbrauch vorhersagen können. Dabei muss die Methode aus den beeinflussten historischen Verbrauchsdaten und anderen verfügbaren relevanten Größen auf das unbeeinflusste Verhalten schließen und dies vorhersagen. Nur mit der Vorhersage der unbeeinflussten Verbrauchszeitreihe kann die Notwendigkeit und die Ausprägung einer Lastbeeinflussung zu einer bestimmten Erzeugungs-Einspeisesituation ermittelt werden. Das Ziel ist der Entwurf einer zeitreihenbasierten Prognosemethode für die Vorhersage von PVV. Die Methode soll auf Basis von Zeitreihen trainierbar sein und so die charakteristischen Eigenschaften des Verbrauchsverhaltens anlernen. Dabei können für verschiedene Beispielzeitreihen die angelernten Modellparameter je nach Individualität der Verbraucher unterschiedlich ausgeprägt sein. Aufgrund der Vorüberlegungen und der Erkenntnisse aus Abschnitt 1 werden folgende Anforderungen an die zu entwerfende Prognosemethode gestellt:

- Vorhersage der beeinflussten und der unbeeinflussten Komponente für preisbeeinflusste Lastzeitreihen,
- Zeitreihenbasierte, trainierbare Methode mit preisbeeinflussten Lastzeitreihen und Preiszeitreihen als Datengrundlage,
- Integration von ζ in Abhängigkeit von Saison, Typtag und Uhrzeit,

- Verarbeitung der Abhängigkeit zur eigenen Zeitreihenvergangenheit (autoregressives Verhalten) des vorherzusagenden Lastverhaltens,
- Berücksichtigung des bei der Lastverschiebung auftretenden Speicherverhaltens,
- Berücksichtigung der Auswirkungen des Planungshorizontes und
- Verarbeitung dynamisch zeitversetzt auftretender Verbraucherreaktionen in Abhängigkeit von Preisereignissen (Kreuz-Preiselastizität).

3.2 Modellentwurf

3.2.1 Erweitertes Komponentenmodell

Für die mathematische Beschreibung von Zeitreihen und deren dynamischen Verhalten stehen in der Literatur umfangreiche Verfahren zur Verfügung. Das klassische Komponentenmodell bietet hierfür einen allgemeingültigen Modellierungsansatz. Dabei wird angenommen, dass eine Zeitreihe aus einem Trendanteil (Polynomansatz) $y_T[k]$, einem periodischen Anteil $y_P[k]$ und einem stochastischen Anteil $y_S[k]$ zusammengesetzt werden kann [13]. Typische Zeitreihen der Energiewirtschaft (wie z. B. Lastgänge) weisen in der Regel charakteristische wiederkehrende Zeitreihenverläufe auf. Um solche typischen Muster besser erfassen zu können, wurde das klassische Komponentenmodell in [14] um eine Musterkomponente $y_M[k]$ erweitert. In diesem Fall kann eine Lastzeitreihe $y[k]$ wie folgt dargestellt werden:

$$y[k] = f(y_T[k], y_P[k], y_S[k], y_M[k]). \quad (5)$$

Zur Beschreibung von preisbeeinflussten Zeitreihen wird das Komponentenmodell um eine weitere Komponente für den beeinflussten Zeitreihenanteil $y_R[k]$ erweitert und die in Gleichung (5) beschriebene Zeitreihe als unbeeinflusste Zeitreihenkomponente $y_U[k]$ definiert. Unter der Annahme eines additiv verknüpften Komponentenmodells (bzw. der Möglichkeit der Überführung in ein additiv verknüpftes Komponentenmodell [13]) ergibt sich eine beeinflusste Lastzeitreihe als Erweiterung von (5) nach folgender Gleichung:

$$\begin{aligned} y[k] &= y_T[k] + y_P[k] + y_S[k] + y_M[k] + y_R[k] \\ &= y_U[k] + y_R[k]. \end{aligned} \quad (6)$$

3.2.2 Modell für die Vorhersage preiselastischer Lastzeitreihen

Die unbeeinflusste Komponente $y_U[k]$ entspricht dabei dem klassischen Prognoseanwendungsfall, bei dem auf die modellbasierte Zeitreihenbeschreibung zurückgegriffen werden kann und in der Literatur bereits zahlreiche Modellansätze existieren. Etablierte Ansätze sind klassische Zeitreihen- und Regressionsmodelle, wie multiple Regressionsmodelle, ARMA-Modelle (AR-autoregressive, MA-moving average) und den darauf aufbauenden Modellen sowie Methoden der Künstlichen Intelligenz, wie Künstliche Neuronale Netze (KNN), Kombinationen mit Fuzzy-Methoden, Support Vector Machines und hybride Modellansätze [15]. Zur Beschreibung von $y_U[k]$ wird auf den ARIMA (autoregressive integrated moving average)-Modellansatz zurückgegriffen. Das in Gleichung (7) beschriebene ARIMA(p,q,d)-Modell (mit weißem Rauschen $\varepsilon[k]$) bietet einen einfachen und etablierten Modellansatz für die Lastprognose und erweitert den ARMA-Modellansatz um d Differenzenfilter. Dabei wird die d -te Differenz $\Delta^d x[k]$ als ARMA(p,q)-Modell der Ordnung p und q modelliert:

$$\Delta^d x[k] = \sum_{i=1}^p [\beta_i \cdot \nabla^d x[k-i]] + \varepsilon[k] + \sum_{j=1}^q \eta_j \cdot \varepsilon[k-j]. \quad (7)$$

Differenzenfilter werden verwendet, um polynomiale Trends einer Zeitreihe durch Differenzenbildung benachbarter Werte zu beseitigen. Der Grad eines polynomialen Trends lässt sich durch Differenzenfilter verringern [13]. Somit werden Differenzenfilter 1. Ordnung zur Beseitigung linearer Trends eingesetzt und Differenzenfilter der Ordnung $d > 1$ zu Beseitigung nichtlinearer Trends. Ziel ist es, Zeitreihen mit typischen wiederkehrenden Mustern oder Trends (z. B. Lastzeitreihen mit Kalenderabhängigkeiten) in Zeitreihen mit quasistationären Eigenschaften zu überführen. Die Verwendung von Differenzenfiltern mit einem entsprechenden Backshift-Operator τ und somit der Berücksichtigung von Referenzwerten $x_{ref}[k] = x[k - \tau]$ erlaubt die Beschreibung solcher Kalenderabhängigkeiten, indem τ durch ein datumsbasiertes Regelwerk vorgegeben wird. Ein Differenzenfilter der ersten Ordnung mit dem Backshift-Operator τ wird in Gleichung (8) und mit d -ter Ordnung in Gleichung (9) beschrieben [14]:

$$\Delta_\tau x[k] = x[k] - x[k - \tau] \quad (8)$$

$$\Delta_\tau^d x[k] = \Delta_\tau^{d-1} x[k] - \Delta_\tau^{d-1} x[k - \tau]. \quad (9)$$

Für die Beschreibung von $y_R[k]$ werden Terme als unabhängige Variablen in der Regressionsfunktion benötigt,

welche die funktionalen Zusammenhänge zwischen Preis- und Laständerung substituieren können. Für die Modellierung der Eigen- und Kreuz-Preiselastizitäten der Matrix Z in L Termen werden dabei mit Hinblick auf die Anzahl der zu schätzenden Parameter Vereinfachungen getroffen. Je nach Grad der Vereinfachungen werden Ausprägungen und Anzahl der Terme und somit die Anzahl der zu schätzenden Parameter festgelegt. Diese $l = 1, \dots, L$ Terme werden mit $\Psi_l[k]$ zusammengefasst und stellen die unabhängigen Variablen in der Regressionsfunktion dar und repräsentieren den Modellierungsansatz für ein preiselastisches Verbrauchsverhalten.

Das für die Vorhersage von preiselastischen Lastzeitreihen verwendete IARIMA-Modell (influenced autoregressive integrated moving average), bestehend aus Teilmodellen für die beeinflusste Zeitreihenkomponente $y_R[k]$ und für die unbeeinflusste Zeitreihenkomponente $y_U[k]$, wird in Gleichung (10) für einen beliebigen Vorhersagehorizont H und den zu bestimmenden Modellparametern δ_l , β_i und η_j aufgeführt:

$$y[k+H] = y_R[k+H] + y_U[k+H] \quad (10)$$

$$= \underbrace{\left\{ \delta_0 + \sum_{l=1}^L \delta_l \Psi_l[k+H] \right\}}_{y_R[k+H]} + \underbrace{\left\{ \sum_{i=1}^p [\beta_i \Delta_\tau^d y_U[k-i]] + \varepsilon[k+H] + \sum_{j=1}^q \eta_j \varepsilon[k-j] + \eta_0 y_{U,ref}[k+H] \right\}}_{y_U[k+H]}.$$

3.2.3 Uhrzeit- und klassenbezogene Modellierung

Elektrische Verbrauchszeitreihen sind in der Regel durch deterministische und stochastische Prozesseigenschaften charakterisiert und sind bspw. über den Ansatz des Komponentenmodells unter Verwendung deterministischer und stochastischer Zeitreihenmodelle beschreibbar. Werden konkrete Realisierungen eines Prozesses unter gleichen Bedingungen beobachtet, dann sind diese Werte einer statistischen Schwankung unterworfen. Die Werte folgen somit einer Wahrscheinlichkeitsverteilung mit bestimmten Parametern. Bei der Betrachtung lokaler Abschnitte von Verbrauchszeitreihen lassen sich in der Regel verschiedene Arbeitspunkte mit sich unterscheidenden Wahrscheinlichkeitsverteilungen beobachten. Für die Modellierung und damit für die Prognose von Prozessen wird in der vorliegenden Arbeit das Konzept der globalen und lokalen Prognose verfolgt. Ein globales Modell (bzw. Modellkomponente) ist für den gesamten Zeitreihenverlauf gültig, während ein lokales Modell nur stückweise

Gültigkeit besitzt. Für die Modellierung lokaler Abschnitte des Prozesses werden separate lokale Modelle verwendet. Eingesetzte separate Modelle (z. B. stochastische Zeitreihenmodelle) sollen dabei lokale Wahrscheinlichkeitsverteilungen des Prozesses, welche lokal individuelle Parameter aufweisen, optimal abbilden. Globale Modellkomponenten justieren den jeweiligen Arbeitspunkt, während die lokale Stochastik mit spezialisierten stochastischen Zeitreihenmodellen abgebildet wird. Als Erweiterung der Mehrschrittmodelle, bei denen separate Modelle pro Vorhersagehorizont verwendet werden [14], wird in der vorliegenden Arbeit die klassenbezogene und uhrzeitabhängige Modellierung (siehe Abbildung 1) eingeführt.

Mit der Identifikation charakteristischer Eigenschaften des Prozesses (als Resultat einer vorab durchzuführenden Datenanalyse) werden dabei lokale Abschnitte des Prozesses durch die Anwendung der Klassifikation identifiziert. Die als Ergebnisse der Datenanalyse zu ermittelnde Klassenstruktur stellt für die gesamte Zeitreihe eine globale Modellkomponente dar. Durch die charakteristischen Eigenschaften von Lastzeitreihen in der Energiewirtschaft lassen sich so typische Klassen c ermitteln. Solche Klassen sind beispielsweise verschiedene Typtage, welche auf ein typisches Verbrauchsverhalten zu verschiedenen Wochentagen, Werktagen oder Wochenenden zurückzuführen sind. Je identifizierter Klasse c wird ein separates lokales Modell verwendet, welches ausschließlich zur

Modellierung der jeweiligen Klasse eingesetzt wird. Dafür werden die Eingangsdaten entsprechend der ermittelten Klassen c zerlegt und in eine Klassenstruktur mit C Klassen eingeordnet.

Bei der uhrzeitabhängigen Modellierung (siehe Abbildung 1) werden als zusätzliche globale Erweiterung separate Modelle für die Beschreibung des Prozesses in Abhängigkeit der Uhrzeit eingesetzt. Für äquidistante Zeitreihen entspricht die Anzahl der Modelle in Abhängigkeit der Abtastzeit T der Anzahl der Werte pro Tag. Ein uhrzeitabhängiges Modell mit dem Index h beschreibt den Prozess für eine Uhrzeit. Die Eingangsdaten werden entsprechend des Uhrzeitindex h zerlegt. Um als Modellausgang wieder eine kontinuierliche Zeitreihe $\hat{y}[k]$ zu erhalten, werden die lokal uhrzeitabhängigen Abschnitte $\hat{y}[k|h = 1, 2, \dots]$ zu den jeweiligen lokal klassenabhängigen Abschnitten $\hat{y}[k|c = 1, \dots, C]$ zusammengesetzt, und diese zu $\hat{y}[k]$ rekonstruiert. Die Vorschrift für die Zerlegung bei der klassenbezogenen und uhrzeitabhängigen Modellierung ist deterministisch und stellt die globale Modellkomponente dar.




Abbildung 1: Klassenbezogene und uhrzeitabhängige Modellierung mit Zerlegung in C Klassen und für eine Abtastzeit von 15 Minuten mit $C \times 96$ Einzelmodellen.

4 Modellvalidierung

4.1 Datengrundlage

Für die Validierung des aufgeführten Modellansatzes werden synthetische Beispieldatensätze verwendet. In realen Datensätzen für preiselastische Lastzeitreihen sind die Zeitreihenkomponenten $y_R[k]$ und $y_U[k]$ nicht separat messbar. Der Vorteil bei der Verwendung synthetischer Datensätze besteht darin, dass die einzelnen Zeitreihenkomponenten bekannt sind und die Untersuchungen unter kontrollierten Bedingungen durchgeführt werden können. Die Leistungsfähigkeit des gewählten Ansatzes zur Prognose kann somit für die beiden einzelnen Zeitreihenkomponenten $y_R[k]$ und $y_U[k]$ validiert werden. Mit Hilfe des Komponentenmodells aus Gleichung (6) werden die synthetischen Beispielzeitreihen für ein Jahr mit einer Abtastzeit von 15 Minuten mit 35 040 Werten generiert. Für einen möglichst realitätsnahen Beispieldatensatz werden folgende charakteristische Eigenschaften entsprechend des erweiterten Komponentenmodells aus Abschnitt 3.2.1 für $y_U[k]$ simuliert.

- Verbrauchsmuster (Tagesmuster) durch kalenderabhängige (bzw. wochentagabhängige) Standardlastprofile,
- Unterschiedliche Lastniveaus in Abhängigkeit von den Typtagen (Wochenrhythmus),
- nichtlinearer Jahrestrend (saisonale Effekte) und
- stochastischer normalverteilter Rauschanteil.

Für die Simulation von $y_R[k]$ werden die Abhängigkeiten zum Einflussparameter Zeit (Uhrzeit, Typtag, Saison) beachtet. Die Matrix Z nach (3), welche die Eigen- und die Kreuz-Preiselastizität beschreibt, wird in Abhängigkeit der Uhrzeit individuell besetzt. In Abhängigkeit von Typtagen und saisonalen Effekten (Unterscheidung in C Klassen) werden jeweils individuelle Matrizen Z_c (pro Klasse c) eingesetzt. Die erzeugten Zeitreihen sind im Bereich 0 und 1 normiert.

Die Abbildung 2 zeigt beispielhaft die mittleren Tageskurven des Beispieldatensatzes für Klassen $c = 1$ (Montag) und $c = 7$ (Sonntag).

Zur Validierung des neuen Modellansatzes anhand realer Daten wird zusätzlich eine Zeitreihe aus einer Feldstudie (Olympic Peninsula Project [16]) herangezogen, bei der das Verbrauchsverhalten von Haushaltsstromkunden mit dynamisch gebildeten RTP (engl. real time price) Stromtarifen von April 2006 bis März 2007 untersucht wurden. Aufgrund der Zusammenstellung der Kunden in der Feldstudie liegt jedoch nur die preisbeeinflusste Lastzeitreihe $y[k]$ für die Untersuchungen vor.

4.2 Ergebnisse

Für die Untersuchungen wurden die synthetischen Beispielzeitreihen sowie die realen Zeitreihen aus dem Projekt Olympic Peninsula im Verhältnis 2/3 zu 1/3 in Trainings- und Testdaten eingeteilt. Die bekannten Zeitreihen für $y_R[k]$ und $y_U[k]$ (bei synthetischem Datensatz) wurden nur für die Berechnung der Prognosefehler verwendet. Ziel ist eine objektive Bewertung des vorgestellten Modellansatzes zur Prognose von PVV für eine rollierende Prognose mit einem Vorhersagehorizont $H = 1, \dots, 96$ Abtastschritten (ein Tag). Zum Vergleich der Prognosequalität für die preisbeeinflusste Lastzeitreihe $y[k]$ wurde ein ARIMAX-Modell (ARIMA mit exogener Größe) und ein KNN-Modell jeweils mit $p[k]$ als exogene Eingangsgröße getestet. Das verwendete KNN-Modell ist ein Feed-Forward-Netz mit drei Schichten, linearen Aktivierungsfunktionen in der Ein- und Ausgabeschicht, Tangens-Hyperbolicus-Aktivierungsfunktion in der verdeckten Schicht und einem Backpropagation-Trainingsalgorithmus [17]. Zunächst wird die Prognosequalität für die preisbeeinflusste Lastzeitreihe $y[k]$ untersucht. Der Prognosefehler $e[k]$ ergibt sich aus Gleichung (11):

$$e[k] = y[k] - \hat{y}[k]. \tag{11}$$




Abbildung 2: Normierte Zeitreihen (mittlere Tageskurve) für Typtagklasse Montag und Sonntag, $y_U[k]$ – unbeflusste Zeitreihenkomponente, $y[k]$ – preisbeeinflusste Lastzeitreihe, $p[k]$ – Preiszeitreihe.

Tabelle 1: Fehlermaße für Prognose der preisbeeinflussten Lastzeitreihe $y[k]$ über Testdaten.

Datensatz	Methode	Mittlerer Fehler	Standardabweichung	Mittlerer absoluter Fehler	Mittlerer quadratischer Fehler
Synthetisch	ARIMAX	0,005	0,0433	0,0335	0,0018
	KNN	0,008	0,0418	0,0325	0,0017
	IARIMA	0,0004	0,0344	0,0273	0,0012
Olympic	ARIMAX	0,017	0,0864	0,0644	0,0076
Peninsula	KNN	0,006	0,0825	0,0620	0,0071
Project	IARIMA	0,004	0,0806	0,0601	0,0066

Tabelle 2: Fehlermaße für Prognose der Zeitreihenkomponenten $y_R[k]$ und $y_U[k]$ über Testdaten.

Methode IARIMA für Zeitreihenkomponente	Mittlerer Fehler	Standardabweichung	Mittlerer absoluter Fehler	Mittlerer quadratischer Fehler
$y_R[k]$	0,00005	0,0232	0,0171	0,00054
$y_U[k]$	0,0004	0,0383	0,0312	0,0014

Für die Bewertung der Prognosequalität werden Mittelwert (mittlerer Fehler – ME), Standardabweichung (STD), Mittelwert des Betrages (mittlerer absoluter Fehler – MAE) und Mittelwert des Quadrates (mittlerer quadratischer Fehler – MSE) des Prognosefehlers als Fehlermaße berechnet. Die Ergebnisse für die Testdaten werden in Tabelle 1 aufgeführt. Die Ergebnisse zeigen, dass das KNN-Modell gegenüber dem ARIMAX-Modell geringere Fehler aufweist. Das neu eingeführt IARIMA-Modell zeigt im Vergleich mit den etablierten Methoden den geringsten Prognosefehler. Der geringe ME zeigt, dass das Modell den Prozess erfasst und der Arbeitspunkt bei leichter systematischer Überschätzung getroffen wurde. Die Untersuchung des Prognosefehlers $e[k]$ für die Gesamtzeitreihe zeigt, dass die vorgestellte Prognosemethode auf Grundlage des IARIMA-Modells im Vergleich zu etablierten Methoden die komplexen funktionalen Zusammenhänge beeinflusster Lastzeitreihen am besten verarbeiten kann und so die besten Prognoseergebnisse liefert.

Für die weiteren Untersuchungen kann nur noch der synthetische Datensatz verwendet werden. Der Prognosefehler für die beeinflusste und die unbeeinflusste Zeitreihenkomponente ergeben sich aus Gleichung (12):

$$e_U[k] = y_U[k] - \hat{y}_U[k], e_R[k] = y_R[k] - \hat{y}_R[k]. \quad (12)$$

Für die Bewertung der Prognosequalität der einzelnen Zeitreihenkomponenten werden ME, STD und MAE von $e_R[k]$ und $e_U[k]$ berechnet. Die Ergebnisse werden in Tabelle 2 aufgeführt. Die Abbildungen 3 und 4 zeigen exemplarisch die mittleren Tageskurven des Beispieldatensatzes für die Prognose- und Istwerte der einzelnen Zeitreihenkomponenten. Dabei ist zu erkennen, dass bei




Abbildung 3: Verlauf (mittlere Tageskurve) der beeinflussten Zeitreihenkomponente $y_R[k]$ und deren Prognose sowie Preiszeitreihe $p[k]$.




Abbildung 4: Verlauf (mittlere Tageskurve) der unbeeinflussten Zeitreihenkomponente $y_U[k]$ und deren Prognose im Vergleich zur preisbeeinflussten Lastzeitreihe $y[k]$ sowie Preiszeitreihe $p[k]$.

der Approximation des Verlaufs von $y_R[k]$ und $y_U[k]$ durch das Modell eine hohe Übereinstimmung vorliegt.

Für eine weitere Auswertung der Prognoseergebnisse werden die Prognosefehler auf die Eigenschaften des

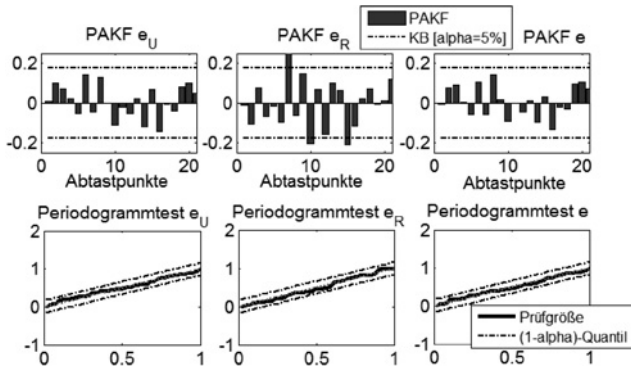


Abbildung 5: Partielle Autokorrelationsfunktion (PAKF) und Periodogrammtest für $e_U[k|h=1]$, $e_R[k|h=1]$ und $e[k|h=1]$ für den Vorhersagehorizont $H=1$.

weißen Rauschens als hinreichendes Kriterium für ein optimales Vorhersagemodell untersucht [13, 14]. Zur Untersuchung der Prognosefehler auf weißes Rauschen werden die partielle Autokorrelationsfunktion (PAKF) sowie der Periodogrammtest verwendet. Der Periodogrammtest ist ein verteilungsunabhängiger Nullhypotesentest, bei dem eine zweiseitige Prüfung des kumulierten Periodogramms gegenüber eines $(1-\alpha)$ -Quantils vorgenommen wird [13]. Das $(1-\alpha)$ -Quantil wird in Abhängigkeit der Irrtumswahrscheinlichkeit α bestimmt. Die Abbildung 5 zeigt exemplarisch die PAKF und den Periodogrammtest der Modellresiduen $e_U[k|h=1]$, $e_R[k|h=1]$ und $e[k|h=1]$ des Vorhersagehorizontes $H=1$. Einzig für den Verlauf der PAKF von $e_R[k|h=1]$ wird das Konfidenzintervall von $\alpha=5\%$ geringfügig verletzt.

Mit dem Periodogrammtest wird die Hypothese, dass die Residuen weißem Rauschen entsprechen, überprüft und für eine Irrtumswahrscheinlichkeit $\alpha=5\%$ dargestellt. Für die untersuchten Beispiele lassen sich keine Verletzungen des $(1-\alpha)$ -Quantils feststellen. Somit kann für alle vorhergesagten Zeitreihenkomponenten die Hypothese auf weißes Rauschen für $h=1$ und $H=1$ angenommen werden.

5 Zusammenfassung und Ausblick

Im vorliegenden Beitrag wird ein neuer Ansatz zur Prognose von PVV vorgestellt, welcher gegenüber dem Einsatz von etablierten Methoden der Lastprognose signifikante Vorteile aufweist. Neben einer besseren Prognosequalität für preisbeeinflusste Lastzeitreihen ist es mit der neuen Methode möglich, die beeinflusste und die unbeeinflusste Zeitreihenkomponente separat vorherzusagen. Die Vorhersage der unbeeinflussten Zeitreihenkomponen-

te stellt dabei den Ausgangspunkt für den Planungsprozess der Preisbildung beim DSM dar. Die mit der Preiseinflussung einhergehenden Effekte, wie die a priori oder a posteriori auftretenden Verbraucherreaktionen, die speicherähnlichen Eigenschaften oder die Zeitvariabilität der Preiselastizität und die damit verbundenen Anforderungen an neue Prognosemethoden wurden untersucht und bei der Modellierung berücksichtigt. Die Untersuchungsergebnisse zeigen anhand eines realen und eines realistischen synthetischen Beispieldatensatzes die Leistungsfähigkeit der neuen Prognosemethode.

Der vorgestellte Ansatz für die Prognose von PVV soll im Rahmen weiterer Untersuchungen verbessert werden. Insbesondere die Berücksichtigung der speicherähnlichen Eigenschaften von DR ist bisher nur unzureichend aufgearbeitet. Weiterhin ist der vorgestellte Modellansatz anhand weiterer realer Beispieldatensätze zu validieren. Insbesondere ist hier eine Erprobung im EnergyLab 2.0 des Karlsruher Instituts für Technologie geplant [18]. Außerdem ist geplant, in den zugrundeliegenden Preis- und Leistungszeitreihen nach typischen Motiven für Preisreaktionen zu suchen, wobei auf vorhandene Methodik zurückgegriffen werden kann, siehe z. B. [19, 20].

Danksagung: Der Dank der Autoren gilt der Deutschen Forschungsgemeinschaft (DFG), die alle Autoren im Rahmen eines Forschungsprojektes (BR 4241/2-1) gefördert hat. Außerdem wurde Ralf Mikut von der Helmholtz-Gemeinschaft innerhalb der gemeinsamen Initiative „Energie System 2050 – Ein Beitrag des Forschungsbereichs Energie“ unterstützt.

Literatur

1. J. S. Vardakas, N. Zorba, C. V. Verikoukis: A Survey on Demand Response Programs in Smart Grids: Pricing Methods and Optimization Algorithms. In: IEEE Communication Surveys, Vol. 17, No. 1, 2015.
2. S. Waczowicz, S. Klaiber, P. Bretschneider, I. Konotop, D. Westermann, M. Reischl, R. Mikut: Data Mining zur Analyse der Auswirkungen von Preissignalen auf Haushaltsstromkunden. In: at – Automatisierungstechnik, Vol. 62, No. 10, pp. 740–752, 2014.
3. S. Klaiber, P. Bretschneider, S. Waczowicz, R. Mikut, I. Konotop, D. Westermann: A Contribution to the Load Forecast of Price Elastic Consumption Behaviour. In: IEEE PowerTech, 2015.
4. N. Yu, J.-L. Yu: Optimal TOU Decision Considering Demand Response Model. In: IEEE International Conference on Power System Technology, 2006.
5. L. Goel, Q. Wu, P. Wang: Reliability Enhancement and Nodal Price Volatility Reduction of Restructured Power Systems with

- Stochastic Demand Side Load Shift. In: IEEE Power Engineering Society General Meeting, 2007.
6. *H. A. Aalami, M. P. Moghaddam, G. R. Yousefi*: Modeling and Prioritizing Demand Response Programs in Power Markets. In: Electric Power Systems Research Vol. 80, pp. 426–435, 2009.
 7. *S. Pflugradt, A. Arnoldt, O. Warweg, P. Bretschneider*: Customer Behavior Model for Load Adjustment and Tariff Forming. In: International Workshop on Integration of Solar Power into Power Systems, 2013.
 8. *S. Waczowicz, M. Reischl, S. Klaiber, P. Bretschneider, I. Konotop, D. Westermann, V. Hagenmeyer, R. Mikut*: Virtual Storages as Theoretically Motivated Demand Response Models for Enhanced Smart Grid Operations. In: Energy Technology, Vol. 4, pp. 63–176, 2016.
 9. *O. Corradi, H. Ochsenfeld, H. Madsen, P. Pinson*: Controlling Electricity Consumption by Forecasting its Response to Varying Prices. In: IEEE Transactions on Power Systems. Vol. 28, No. 1, 2013.
 10. *Q. Wang, J. Wang, Y. Guan*: Stochastic Unit Commitment with Uncertain Demand Response. In: IEEE Transaction on Power Systems, Vol. 28 No. 1, 2013.
 11. *D. S. Kirschen, G. Strbac, P. Cumperayot, D. de Paiva Mendes*: Factoring the Elasticity of Demand in Electricity Prices. In: IEEE Transactions on Power Systems, Vol. 15, No. 2, pp. 612–617, 2000.
 12. *I. Konotop, S. Klaiber, S. Waczowicz, P. Bretschneider, R. Mikut, D. Westermann*: Investigation and mathematical modeling of the impact of incentive signals to consumers on their consumption, load forecasts and network operation. IET Generation, Transmission & Distribution, Vol. 10, No. 9, pp. 2138–2146, 2016.
 13. *R. Schlittgen, B. Streitberg*: Zeitreihenanalyse. 9. Auflage, Oldenbourg Wissenschaftsverlag München Wien, 2001.
 14. *P. Bretschneider*: Ein Beitrag zur Vorhersage musterbasierter nichtlinearer stochastischer Signale. Dissertation, Verlag ISLE, Ilmenau, 2002.
 15. *H. Hahn, S. Meyer-Nieberg, S. Pickl*: Electric Load Forecasting Methods: Tools for Decision Making. In: European Journal of Operational Research, Vol. 199, No. 3, pp. 902–907, 2009.
 16. *D. Hammerstrom, R. Ambrosio, J. Brous, et al.*: Pacific Northwest GridWise Testbed Demonstration Projects. Part I. Olympic Peninsula Project, 2007.
 17. *D. Pham, X. Liu*: Neural Networks for Identification, Prediction and Control. Springer-Verlag London, 1995.
 18. *V. Hagenmeyer, H. K. Cakmak, C. Döpmeier, T. Faulwasser, J. Isele, H.-B. Keller, P. Kohlhepp, U. Kühnapfel, U. Stucky, S. Waczowicz, R. Mikut*: Information and Communication Technology in Energy Lab 2.: Smart Energies System Simulation and Control Center with an Open-Street-Map-based Power Flow Simulation Example. In: Energy Technology, Vol. 4, pp. 145–162, 2016.
 19. *A. Mueen, E. Keogh*: Online Discovery and Maintenance of Time Series Motifs. Proc, 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 1089–1098, 2010.
 20. *G. Herbst*: Unscharfe Verfahren für lokale Phänomene in Zeitreihen TU Chemnitz. Dissertation, TU Chemnitz, 2011.

Autoreninformationen

Dipl.-Ing. Stefan Klaiber

Institutsteil Angewandte Systemtechnik (AST) des Fraunhofer IOSB,
Am Vogelherd 50, 98693 Ilmenau, Tel.: 03677-46-1105
stefan.klaiber@iosb-ast.fraunhofer.de

Dipl.-Ing. Stefan Klaiber ist wissenschaftlicher Mitarbeiter des Fraunhofer IOSB-AST. Hauptarbeitsgebiete: Energieprognosen, Energiedatenmanagement und Modellbildung.

Dipl.-Ing. Simon Waczowicz

Institut für Angewandte Informatik (IAI), Karlsruher Institut für Technologie (KIT), Hermann-von-Helmholtz-Platz 1, 76344 Eggenstein-Leopoldshafen, Tel.: 0721-608-26713
simon.waczowicz@kit.edu

Dipl.-Ing. Simon Waczowicz ist wissenschaftlicher Mitarbeiter im Institut für Telematik am KIT. Hauptarbeitsgebiete: Modellierung von Energiesystemen, Datenanalyse.

Dipl.-Ing. Irina Konotop

Fachgebiet Elektrische Energieversorgung, Technische Universität Ilmenau,
Gustav-Kirchhoff-Straße 1, 98684 Ilmenau, Tel.: 03677-69-1490
irina.konotop@tu-ilmenau.de

Dipl.-Ing. Irina Konotop ist wissenschaftliche Mitarbeiterin an der Fakultät für Elektrotechnik und Informationstechnik im Fachgebiet Elektrische Energieversorgung an der TU Ilmenau. Hauptarbeitsgebiete: Netzbetrieb mit steuerbaren Verbrauchern, Optimierung.

Prof. Dr.-Ing. Dirk Westermann

Fachgebiet Elektrische Energieversorgung, Technische Universität Ilmenau,
Gustav-Kirchhoff-Straße 1, 98684 Ilmenau, Tel.: 03677-69-2838
dirk.westermann@tu-ilmenau.de

Prof. Dr.-Ing. Dirk Westermann ist Professor an der Fakultät für Elektrotechnik und Informationstechnik im Fachgebiet Elektrische Energieversorgung an der TU Ilmenau. Forschungsschwerpunkte: Betriebsführung und -analyse sowie -design der zukünftigen elektrischen Energiesysteme.

Prof. Dr.-Ing. Ralf Mikut

Institut für Angewandte Informatik (IAI),
Karlsruher Institut für Technologie (KIT), Hermann-
von-Helmholtz-Platz 1, 76344 Eggenstein-
Leopoldshafen, Tel.: 0721-608-25731

ralf.mikut@kit.edu

Prof. Dr.-Ing. Ralf Mikut ist außerplanmäßiger Professor an der Fakultät für Maschinenbau des KIT und Projektleiter am Institut für Angewandte Informatik (IAI). Forschungsschwerpunkte: Computational Intelligence, Data Mining, Biosignalanalyse, Bildverarbeitung, Regelungstechnik, Robotik, Bewegungsanalyse, Modellierung von Energiesystemen.

Dr.-Ing. Peter Bretschneider

Institutsteil Angewandte Systemtechnik (AST) des
Fraunhofer IOSB,
Am Vogelherd 50, 98693 Ilmenau, Tel.:
03677-46-1102

**peter.bretschneider@iosb-
ast.fraunhofer.de**

Dr.-Ing. Peter Bretschneider ist Leiter der Abteilung Energie des Fraunhofer IOSB. Forschungsschwerpunkte: Energiemanagement, Zeitreihenanalyse und Prognose, Optimierung und Betriebsführung in Stromversorgungsnetzen, Smart Grids und Energiemärkte.