

Aggregatorentscheidungen zum Angebot von Flexibilität an Strommärkten auf Grundlage von Prognosen mittels Zeitreihenanalyse

Lennart Ross*, Felix Heider, Detlef Schulz
Fachbereich Elektrische Energiesysteme
Helmut-Schmidt-Universität / Universität der Bundeswehr Hamburg
Hamburg, Deutschland
*lennartross99@googlemail.com

Kurzfassung – Private Haushalte können durch die zur Verfügung gestellte Flexibilität einen Beitrag zum Demand Side Management liefern. Um einen finanziellen Anreiz zu bieten, könnte die aggregierte Flexibilität mehrerer Haushalte an einer Strombörse gehandelt werden. Dazu muss ein Aggregator über Prognosen der bereitgestellten Flexibilität und der Strompreise verfügen, um eine Entscheidung über den idealen Angebotszeitpunkt treffen zu können. Dieser bestimmt sich durch den höchstmöglichen Ertrag, der für die beteiligten Haushalte generiert werden kann. Der Aggregator muss über eine Systematik verfügen, diesen auszuwählen. In dieser Arbeit wird untersucht, inwiefern die mathematischen Modelle ARIMA und TBATS befähigt sind, Prognosen über bereitgestellte Flexibilität und Strompreise zu treffen. Weiterhin wird auf Grundlage dieser Untersuchungen eine Heuristik entwickelt und getestet, mit welcher ein Aggregator Entscheidungen über den Zeitpunkt des Angebots treffen kann.

Stichworte – Flexibilität, Prognose, Strommarkt, Demand Side Management, Aggregator

NOMENKLATUR

EE	Erneuerbare Energien
EEX	European Energy Exchange
DMS	Demand Side Management
EMS	Energiemanagementsystem
KI	Künstliche Intelligenz

I. EINLEITUNG

Der zunehmende Anteil Erneuerbarer Energien (EE) an der Gesamtenergieerzeugung stellt Herausforderungen für die sichere Energieversorgung dar. Mittelfristig wird mehr als die Hälfte der erzeugten Energie aus EE stammen [1, S. 6], bis 2050 könnten sogar 80 % des Bruttostromverbrauchs aus EE stammen [2]. Daraus folgt eine steigende Volatilität hinsichtlich der Erzeugungsleistung. Bereits 2025 wird von bis zu 1000 Stunden ausgegangen, in denen sich die Einspeiseleistung von EE innerhalb einer Stunde um 5 GW ändern könnte [1, S. 7].

Die durch den steigenden Anteil von EE hervorgerufene Volatilität wird zu Überschüssen und zu sogenannten Dunkelflauten (wenn die Einspeiseleistung Erneuerbarer Energien vernachlässigbar gering ist) führen. Das An- und Abfahren konventioneller Kraftwerke orientiert sich daher

auch an Prognosen der Einspeiseleistung von EE [3]. Diese werden die durch EE erzeugte Fluktuation nicht mehr alleine auffangen können [4]. Daher besteht Bedarf an sogenannten Flexibilitätsoptionen, Technologien, die Flexibilität bereitstellen [2]. Das können flexible Kraftwerke wie Gaskraftwerke oder Speichertechnologien sein. Weiterhin kann Flexibilität auch durch das Steuern der Nachfrageseite generiert werden. Diese Flexibilisierung der Nachfrage, auch als Demand Side Management (DMS) bezeichnet, kann in Form von Lastverschiebung erfolgen. Lastverschiebung charakterisiert sich dadurch, dass sich die Nachfrage flexibel am Angebot orientiert und die Nutzung dieser Lasten entsprechend an die Verfügbarkeit angepasst wird [3].

Das Lastverlagerungspotential privater Haushalte ist sehr hoch. In [5] wird für das Jahr 2030 von einem Lastverlagerungspotential privater Haushalte von bis zu 20 GW im Winter und bis zu 18 GW im Sommer ausgegangen. Zum Steuern des Energieverbrauchs in einem Haushalt ist ein steuerbares Managementsystem notwendig. Dieses kann in Form eines Energiemanagementsystems (EMS) realisiert werden, in welches Nutzerpräferenzen eingegeben werden können. Dieses kann gemäß der in [6] dargestellten Methodik unter Einhaltung der durch den Endnutzer definierten Grenzen Geräte des Haushalts zu- oder abschalten, um so Flexibilität bereitzustellen. Bezieht eine Waschmaschine während des Waschgangs beispielsweise 3 kW, stehen diese 3 kW bei einer kurzfristigen Abschaltung der Waschmaschine (mit der Intention, diese nach einer vom Endnutzer definierten Zeit wieder anzuschalten) zur Verfügung, um beispielsweise an einem Strommarkt angeboten zu werden, oder sie können dazu beitragen, eine aktuelle Lastspitze zu reduzieren. Dieser Zusammenhang wird in Gleichung 1 verdeutlicht: Die erzeugte Flexibilität in einem Zeitintervall i entspricht der Differenz der verbrauchten Leistung im Haushalt vor ($P_{pre,i}$) und während ($P_{post,i}$) eines Flexibilitätsevents.

$$P_{flex,i} = P_{pre,i} - P_{post,i} \quad (1)$$

Analog der Methodik aus [6] können Präferenzen des Endnutzers beispielsweise die Anzahl der Pausen sein, die eine Waschmaschine während eines Waschgangs machen darf, oder aber auch die maximal geduldete Pausenlänge. Was der einzelne Haushalt zu einer Flexibilisierung des Energieverbrauchs beitragen kann, hängt von den technischen Gegebenheiten und der Zusammensetzung des Haushalts sowie von der Einstellung der Bewohner gegenüber dem

eigenen Energieverbrauch ab. Grundsätzlich kann ein Interesse zur Flexibilisierung des eigenen Energieverbrauchs unterstellt werden [5].

Um einen monetären Anreiz für das Bereitstellen von Flexibilität zu bieten, wäre es denkbar, diese, zu handelbaren Mengen aggregiert, an Strommärkten zu handeln. Durch Aggregation können auch Flexibilitäten in geringer Höhe und von kurzer Verfügbarkeit zu vermarktbar aggregaten gebündelt werden [7]. Ein Aggregator kann das Potential verschiedener Haushalte bündeln und deren unterschiedliche Eigenschaften (unterschiedliche Zusammensetzungen und technische Möglichkeiten) kombinieren [8].

Dem Aggregator würde die Entscheidung über den Zeitpunkt des Angebots von bereitgestellter Flexibilität, mit dem Ziel, den höchstmöglichen Ertrag zu generieren, obliegen. Dieser hängt von der abrufbaren Flexibilität und vom gegenwärtigen Strompreis, zu dem die Flexibilität gehandelt werden kann, ab. Der Aggregator steht vor einem Optimierungsproblem, ohne alle Werte zu kennen. Für seine Entscheidung muss der Aggregator daher auf Prognosen zurückgreifen.

Für die Prognosen von Strompreisen und Stromlasten wird oft auf Methoden der Zeitreihenanalyse (im Folgenden als statistische, mathematische oder traditionelle Methoden bezeichnet) oder auf Künstliche Intelligenz (KI) zurückgegriffen. Gemäß [9] wird für die Prognose von Strompreisen sowohl auf statistische Methoden als auch auf Methoden der KI sowie zunehmend auf hybride Methoden zurückgegriffen. Methoden der KI gehören zu den beliebtesten Methoden, da sie komplexe, nichtlineare Trends identifizieren können. Nach [10] können die für die Prognose von Lasten üblichen Prognoseverfahren in traditionelle und moderne Vorhersagemethoden differenziert werden. Erstere sind neben der Multiplen Linearen Regression das Anpassen stochastischer Modelle und Exponentielles Glätten. Zu den modernen Vorhersagemethoden zählen unter anderem Neuronale Netze (KI) und hybride Methoden.

In [11] werden die Fähigkeiten von ARIMA-Modellen, TBATS-Modellen – beides statistische Methoden – und Neuronalen Netzen (KI) zur kurzfristigen Lastprognose einzelner Haushalte untersucht. Nach [11] ist die Genauigkeit sämtlicher Methoden eher gering.

Der Nachteil von Methoden der Zeitreihenanalyse gegenüber hybriden Ansätzen ist, dass sie sich ausschließlich historischer Daten bedienen und keine Umwelteinflüsse berücksichtigen. Außerdem sind Neuronale Netze eher als statistische Modelle geeignet, komplexe Trends zu erkennen. Entsprechende Modelle können jedoch mit verhältnismäßig geringem Aufwand aufgestellt werden.

Im Folgenden werden Methoden der Zeitreihenanalyse verwendet, um Strompreise des kontinuierlichen Intraday-Handels der EEX und abrufbare aggregierte Flexibilitäten zu prognostizieren. In dieser Arbeit wird untersucht, ob die Prognosen mathematischer Modelle trotz der erwähnten Mängel als Grundlage für eine Heuristik dienen können, die dazu befähigt ist, Entscheidungen über das Angebot von Flexibilitäten an Strommärkten zu treffen. Der auf Grundlage dieser Untersuchungen entwickelte Algorithmus wird getestet und die Ergebnisse evaluiert.

II. DATENGRUNDLAGE

A. Stromhandel

Der börsliche Handel bietet Transparenz und einfache Abwicklungen [12, S. 18]. Es wird in den Termin- und Spotmarkt, sowie in den Intraday-Handel, unterschieden. Der Intraday-Handel ist dazu prädestiniert, auf identifizierte Prognoseabweichungen zu reagieren [2]. Der Intraday-Handel kann wiederum in den kontinuierlichen Intraday-Handel und die Intraday-Auktion unterschieden werden [13, 91 f.]. Bei ersterem können kontinuierlich Stunden- und Viertelstundenkontrakte bis fünf Minuten vor der Lieferung gehandelt werden, es kommt zu keinen einheitlichen Preisen, sondern zu individuellen Gebotspreisen [14]. Durch die Viertelstundenkontrakte wird es auch Anbietern mit kurzen Bereitstellungszeiträumen ermöglicht, Energie anzubieten [2]. Bei der Intraday-Auktion können Viertelstundenkontrakte um 15 Uhr des Vortages erworben werden, es werden einheitliche Preise, der sogenannte Markträumungspreis, gebildet [14].

Für die Untersuchungen wurden die kontinuierlichen 15-Minuten-Preise des Intraday-Handels an 14 Wochentagen betrachtet.

B. Simulation

Die Daten der aggregierten abrufbaren Flexibilität werden der in [6] diskutierten Simulation entnommen. Die in MATLAB Simulink implementierte Simulation wird in Echtzeit auf dem Echtzeitsimulator OPAL-RT 5707 ausgeführt. Bestandteil der Simulation sind verschiedene Haushaltskonfigurationen gemäß sozio-ökonomischer Faktoren der betrachteten Region und deren EMS. Die Erzeugung einer beliebigen Menge an individuell ausgestatteten Haushalten ist somit möglich. Die Zusammensetzung des Haushalts, die Anzahl der steuerbaren Geräte sowie die aktuell anwesenden Personen unterliegen einer Wahrscheinlichkeitsverteilung. Der Zufall entscheidet, mit welchen Geräten ein Haushalt ausgestattet ist, wann welches Gerät in Betrieb genommen wird und wie viele Bewohner zum jeweiligen Zeitpunkt anwesend sind [15].

Der simulierte Gesamtverbrauch des Haushalts setzt sich aus dem Verbrauch einzelner Geräte zusammen. Dieser wird in Echtzeit aufsummiert, um das Lastprofil des gesamten Haushalts zu erstellen, wie in Gleichung 2 zu erkennen ist. Die Summe aller Lasten P_n im Zeitintervall i ergibt den Gesamtverbrauch des Haushalts im Zeitintervall i $P_{i,ges}$. Die Anzahl der Lasten n variiert im Laufe der Zeit.

$$P_{i,ges} = \sum_{n=1}^N P_{i,n} ; \forall i \in I, \forall n \in N \quad (2)$$

Das EMS greift auf die aktuellen Zustände und relevanten Parameter der steuerbaren Geräte sowie getätigte Endnutzereingaben und auf bekannte Parameter, die sich auf Zustände von steuerbaren Geräten auswirken können, zurück, um die abrufbare Flexibilität zu berechnen [6].

Diese wird in Form einer Matrix kommuniziert, welche in Gleichung 3 dargestellt ist.

Aus dieser geht für jedes Zeitintervall i in 15-Minuten-Schritten für jeden Zeitpunkt bzw. jeden möglichen Beginn eines Flexibilitätsevents und für jede mögliche Dauer eines Flexibilitätsevents die zur Verfügung stehende Flexibilität hervor [6]. Die Zeilen geben mögliche Startzeitpunkte und die Spalten mögliche Endpunkte an. So ist die in der Matrix

dargestellte Leistung $P_{2,1,i}$ im Zeitintervall i in 30 Minuten für 15 Minuten abrufbar.

$$P_{flex,i} = \begin{bmatrix} P_{1,1,i} & P_{1,2,i} & P_{1,3,i} & P_{1,4,i} \\ P_{2,1,i} & P_{2,2,i} & P_{2,3,i} & P_{2,4,i} \\ P_{3,1,i} & P_{3,2,i} & P_{3,3,i} & P_{3,4,i} \\ P_{4,1,i} & P_{4,2,i} & P_{4,3,i} & P_{4,4,i} \end{bmatrix} \quad (3)$$

Für die Untersuchungen wurde die aggregierte Flexibilität von 50 Haushalten, von denen 22 über steuerbare Geräte verfügen, an 12 Wochentagen betrachtet.

III. ZEITREIHENANALYSE

Eine Zeitreihe besteht aus einer endlichen Menge von Beobachtungen $x_1, x_2 \dots x_T$ von T Zufallsvariablen $X_1, X_2, \dots X_T$, deren angenommene Werte über die Zeit T gemessen und entsprechend geordnet wurden. Die Zeit entspricht daher im diskreten Fall der Indexmenge $t = 1, 2, 3, \dots T$. Eine Realisierung von einer Zeitreihe kann wie folgt dargestellt werden: $X = X_1, X_2, \dots X_T$ [16, S. 2]. Die Analyse einer solchen Zeitreihe (Zeitreihenanalyse) dient dem Beschreiben und Erklären der zeitlichen Entwicklung der Variable X , aber auch der Prognose von zukünftigen Werten von X [17, S. 136]. Dazu müssen Regelmäßigkeiten und Muster, die sich wahrscheinlich in der Zukunft wiederholen werden, identifiziert werden [16, 1 f.].

A. Stochastische Prozesse

Für die Prognose weiterer Werte der Zeitreihe müssen die beobachteten Werte an das Modell eines stochastischen Prozesses angepasst werden. Der stochastische Prozess ist das mathematische Modell, welches die Zeitreihe beschreibt [18, S. 18]. Ein stochastischer Prozess ist eine Familie von Zufallsvariablen bzw. eine Realisierung $X_t, t \in T$ mit dem gemeinsamen Wahrscheinlichkeitsraum (Ω, Σ, P) über die Indexmenge T [18, 19 f.].

Die nichtleere Menge Ω ist die sogenannte Ergebnismenge, die Menge Σ bestehend aus Teilmengen von Ω wird als Ereignismenge oder auch σ -Algebra und P als Wahrscheinlichkeitsmaß bezeichnet. Alle möglichen zufällige Ereignisse bzw. Ausgänge eines Versuchs sind Teilmengen von Ω , diese Teilmengen bilden die Ereignismenge. Das Wahrscheinlichkeitsmaß P ordnet den zufälligen Ereignissen eine Wahrscheinlichkeit zu [18, 19 f.].

Die Zeitreihe kann als Realisierung eines stochastischen Prozesses verstanden werden, bzw. stellt einen Ausschnitt von diesem dar [18, S. 18]. Mittels der Analyse der vorliegenden Zeitreihe werden die Eigenschaften des vorliegenden Prozesses identifiziert.

B. ARIMA-Modell

Ein stationärer, stochastischer Prozess X_t mit der Gleichung

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots \varphi_p X_{t-p} + \varepsilon_t \quad (4)$$

wird als autoregressiver Prozess p -ter Ordnung oder als AR(p)-Prozess bezeichnet, wenn er stationär ist. Der Zustand X_t ist von ε_t abgesehen lediglich von p durch die Koeffizienten $\varphi_1 \dots \varphi_p$ unterschiedlich gewichteten, vergangenen Zuständen desselben Prozesses abhängig [18, S. 80].

Bei einem MA(q)-Prozess handelt es sich um einen ebenfalls stationären Prozess, dessen Zustand von einem Weißen Rauschen und vergangenen gewichteten Werten eines Weißen Rauschens abhängt, wie in Gleichung 5 verdeutlicht wird [18, S. 90].

$$X_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (5)$$

Ein stochastischer Prozess kann als Summe zweier unkorrelierter stochastischer Prozesse gebildet werden [18, S. 98]. So kann aus der Summe eines AR(p)- und eines MA(q)-Prozesses ein ARMA(p, q)-Prozess gebildet werden, dargestellt in Gleichung 6. Durch die Bildung eines ARMA-Prozesses lässt sich eine Zeitreihe mit weniger Koeffizienten nachbilden als bei entsprechend angepassten allein stehenden Prozessen [18, S. 100].

$$X_t = \sum_{i=1}^p \varphi_i d_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (6)$$

ARMA-Modelle werden auf stationäre Zeitreihen angepasst, in der Praxis werden meist instationäre Zeitreihen beobachtet. Durch Differenzieren der Zeitreihe kann diese in eine stationäre Zeitreihe umgewandelt werden. Weist ein stochastischer Prozess beispielsweise einen linearen Trend $a * t$ auf, kann dieser durch eine einfache Differenzbildung eliminiert werden [18, S. 121]. Durch mehrfaches Differenzieren können auch nichtlineare Trends entfernt werden. Man spricht von einem differenzierten oder auch integrierten Prozess. Ein ARMA(p, q)-Prozess wird durch d -faches Differenzieren zum ARIMA(p, d, q)-Prozess [18, S. 123].

Unter Berücksichtigung einer saisonalen Komponente wird ein ARIMA(p, d, q)x(P, D, Q) $_m$ -Modell oder auch SARIMA (für saisonales ARIMA) gebildet [18, S. 136].

C. TBATS-Modell

Das BATS-Modell von Livera, Hyndman und Snyder baut auf einer Erweiterung des Holt-Winters-Verfahren durch Taylor [19] auf und wird in [20] und [21] beschrieben. Mittels einer Box-Cox-Transformation werden die beobachteten Werte der Zeitreihe so transformiert, dass sie nahe bzw. näher an einer Normalverteilung liegen. Dazu wird ein passender Exponent ω im Bereich -3 bis 3 verwendet, siehe Gleichung 7. Die Zeitreihe selbst wird in die Niveauekomponente l_t , den Trendzuwachs b_t , die i -te saisonale Komponente zum Zeitpunkt t $s_t^{(i)}$ und eine Fehlerkomponente d_t zerlegt (Gleichung 8). Die Koeffizienten werden mit Hilfe der Glättungsfaktoren α, β und γ berechnet (Gleichung 9 bis 11). Weiterhin wird der Trendzuwachs mit dem Dämpfungsfaktor ϕ gedämpft. Die Fehlerkomponente wird durch ein ARMA-Modell, dargestellt in Gleichung 12, modelliert.

$$x_t^{(\omega)} = \begin{cases} \frac{x_t^{(\omega)} - 1}{\omega} & \omega \neq 0 \\ \text{Log } x_t & \omega = 0 \end{cases} \quad (7)$$

$$x_t^{(\omega)} = l_{t-1} + \phi b_{t-1} + \sum_{i=1}^M s_{t-m_i}^{(i)} + d_t \quad (8)$$

$$l_t = l_{t-1} + \phi b_{t-1} + \alpha d_t \quad (9)$$

$$b_t = \phi b_{t-1} + \beta d_t \quad (10)$$

$$s_t^{(i)} = s_{t-m_i}^{(i)} + \gamma_i d_t \quad (11)$$

$$d_t = \sum_{i=1}^p \varphi_i d_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (12)$$

Das BATS-Modell hat die Notation $(\omega, \phi, p, q, m_1, m_2, \dots, m_M)$. Die Parameter p und q entstammen dem ARMA-Modell, ϕ ist der Dämpfungsfaktor, ω entspricht dem für die Box-Cox-Transformation ausgewählten Parameter, m_1, m_2, \dots, m_M entsprechen den verschiedenen saisonalen Schwankungen bzw. Frequenzen [21].

Das TBATS ist eine Erweiterung des BATS, welche sich vom BATS lediglich durch die Modellierung der saisonalen Komponente unterscheidet [21]. Man stützt sich auf einen in [22] vorgestellten Ansatz. Die Saisonalitäten werden durch trigonometrische Darstellungen auf Grundlage einer Fourier-Analyse modelliert. Die Anzahl der verschiedenen identifizierten Saisonalitäten wird mit M angegeben. Jede i -te Saisonkomponente wird durch k Oberschwingungen dargestellt [21].

Die i -te Saisonkomponente zum Zeitpunkt t ergibt sich daher aus der Summe von k_i Oberschwingungen, wie in Gleichung 13 zu sehen ist.

$$s_t^{(i)} = \sum_{j=1}^{k_i} s_{j,t}^{(i)} \quad (13)$$

Grundsätzlich sind bessere Prognosen als mit dem BATS möglich, unter anderem da die Saisonalitäten nicht ganzzahlig sein müssen und ineinander verschachtelte Saisonalitäten berücksichtigt werden können [21].

Die Notation des Modells ergibt sich nach [21] zu $\omega, \phi, p, q, \{m_1, k_1\}, \{m_2, k_2\}, \dots, \{m_M, k_M\}$.

IV. MODELLBILDUNG

Die Modelle wurden mit der Open-Source-Programmiersprache R, die vor allem für die Lösung und Bearbeitung statistischer Problemstellungen und Aufgaben geeignet ist [23, S. 5], gebildet. Mittels der Funktion `arima()`, der neben der Zeitreihe lediglich ein Vektor in der Form (p,d,q) übergeben werden muss, können Parameter gemäß der Maximum-Likelihood-Methode geschätzt werden.

Das `forecast package` von Hyndman und Khandakar beinhaltet unter anderem einen ARIMA-Algorithmus, um die ideale Notation zu bestimmen [24]. Der entsprechenden Funktion `auto.arima()` kann eine Zeitreihe übergeben werden, die daraufhin selbstständig das beste Modell anpasst. Das von De Livera, Hyndman und Snyder entwickelte TBATS-Modell kann mit der ebenfalls im `forecast package` enthaltenen Funktion `tbats()` angepasst werden [25].

Ein mit diesen Funktionen angepasstes Modell kann an die Funktion `forecast()` übergeben werden, welche die entsprechenden Prognosen für die gewünschte Anzahl an Zeitschritten berechnet [25].

A. Validierung der Modelle

Für die Validierung der Modelle wurden die sogenannten Residuen betrachtet. Nachdem alle Komponenten des Modells richtig identifiziert worden sind, sind die Residuen der übrig gebliebene Rest [18]. Sie sind daher gut geeignet, um zu überprüfen, ob das gewählte Modell die vorliegenden Beobachtungen gut analysiert bzw. erfasst hat [25, Kapitel 3.3].

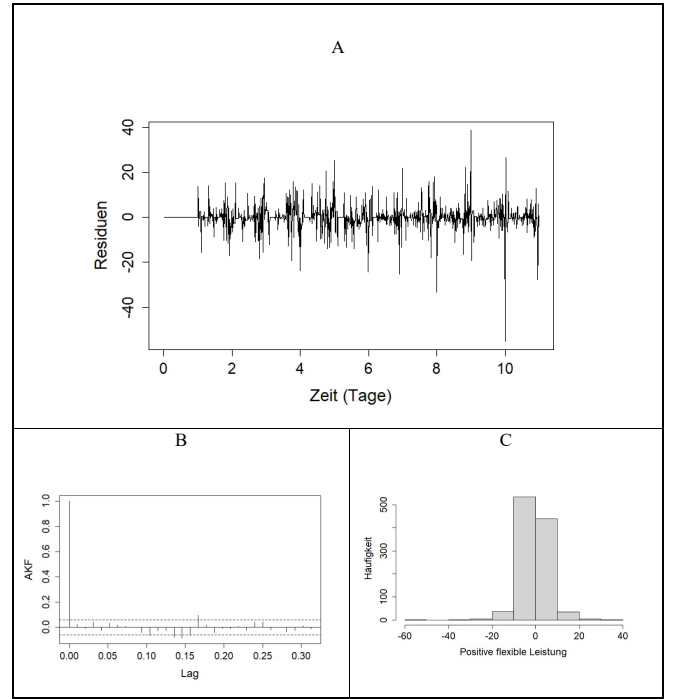


ABBILDUNG 1: DIE ANALYSE DER RESIDUEN EINES GEBILDETEN MODELLS. IN A SIND DIE RESIDUEN EINES ANGEPASTEN MODELLS DARGESTELLT. DIE AUTOKORRELATIONSFUNKTION DER RESIDUEN IST IN B UND DAS HISTOGRAMM DER RESIDUEN IN C DARGESTELLT.

Ist das gewählte Modell geeignet, sollten keine relevanten Informationen mehr in den Residuen enthalten sein. Das heißt, die Residuen sollten unkorreliert sein und einen Mittelwert von Null haben. Ferner ist es vorteilhaft, aber nicht zwingend notwendig, wenn die Residuen normalverteilt sind und eine konstante Varianz haben. Ein Mittelwert ungleich Null deutet auf eine verzerrte Prognose hin, Korrelation zwischen den Residuen weist auf Informationen hin, die nicht in die Bildung des Modells eingegangen sind [25]. Im Idealfall bilden die Residuen ein Weißes Rauschen [18, S. 59].

Mit der Funktion `checkresiduals()` aus dem `forecast-Paket` können die Residuen optisch überprüft werden. Diese Funktion führt gleichzeitig den Ljung-Box-Test durch, welcher die Residuen auf Autokorrelation untersucht [25].

In ABBILDUNG 1 sind die Residuen eines gebildeten Modells sowie die Autokorrelationsfunktion und ein Histogramm der Residuen dargestellt.

B. Güte der Prognosen

Für die Bewertung der Prognoseergebnisse wurden auf den MAPE, den MAE und den Ungleichheitskoeffizienten von Theil U zurückgegriffen. Der mittlere absolute prozentuale Fehler MAPE (aus dem Englischen *mean absolute percentage error*) wurde für die Prognose der Strompreise verwendet. Der MAPE wird berechnet, indem die Abweichung der Prognose P_t für den Wert des Zustands W_t auf diesen normiert und über die Anzahl aller Prognosen h aufsummiert wird. Diese Summe wird anschließend durch h dividiert, wie in Gleichung 14 zu sehen ist. [18, S. 15]

$$MAPE = \frac{100\%}{h} \sum_{t=n+1}^{n+h} \left| \frac{P_t - W_t}{W_t} \right| \quad (14)$$

Für die Beurteilung der Güte der Prognose der Flexibilität wurde nicht auf den MAPE, sondern auf den MAE, den mittleren absoluten Fehler, zurückgegriffen, welcher gemäß Gleichung 15 berechnet wird [18, S. 16].

Dieser wurde verwendet, da die beobachtete Flexibilität regelmäßig Null betrug und beim MAPE durch diesen Wert geteilt werden müsste.

$$MAE = \frac{1}{h} \sum_{t=n+1}^{n+h} |P_t - W_t| \quad (15)$$

Sowohl beim MAPE wie auch beim MAE ist die Beurteilung des Ergebnisses problematisch, da sie subjektiv erfolgt. Der Beurteilende muss selbst entscheiden, ob das Ergebnis „gut“ oder „schlecht“ ist. Mit dem Ungleichheitskoeffizienten von Theil U können unterschiedliche Prognoseverfahren verglichen werden. Zumeist werden die Ergebnisse des gewählten Verfahrens mit der sogenannten „naiven Prognose“ verglichen. Diese prognostiziert für einen Wert stets den vorherigen Wert. Für $U < 1$ war das gewählte Prognoseverfahren besser als die naive Prognose. $U > 1$ bedeutet, dass das gewählte Modell der naiven Prognose unterlegen und somit nicht geeignet ist [18, S. 17]. Die Berechnung des Ungleichheitskoeffizienten ist in Gleichung 16 dargestellt.

$$U = \sqrt{\frac{\sum_{t=n+1}^{n+h} (P_t - W_t)^2}{\sum_{t=n+1}^{n+h} (W_{t-1} - W_t)^2}} \quad (16)$$

Außerdem wurde die Fähigkeit des Modells, Trends zu erkennen, untersucht. Dazu wurde folgendes angenommen: Wenn die Prognose für einen zukünftigen Zeitpunkt größer als der gegenwärtige Wert und gleichzeitig der tatsächliche zukünftige Wert kleiner als der gegenwärtige Wert ist, wurde fälschlicherweise ein Aufwärtstrend prognostiziert, obwohl ein Abwärtstrend vorliegt. Entsprechend wurde fälschlicherweise ein Abwärtstrend prognostiziert, obwohl ein Aufwärtstrend vorliegt, wenn die Prognose für einen zukünftigen Zeitpunkt kleiner als der gegenwärtige Wert und gleichzeitig der tatsächliche zukünftige Wert größer als der gegenwärtige Preis ist.

C. Erstellen der Prognosen

Für die Prognose der abrufbaren Flexibilität wurde auf die aggregierte Flexibilität von 50 Haushalten von 12 Wochentagen zurückgegriffen, zu sehen in ABBILDUNG 2. Die Daten wurden der in [6] diskutierten Simulation entnommen. Als Zeitreihe dienen die Werte der ersten Spalte der ersten Zeile der in Gleichung 3 dargestellten Matrix. Es handelt sich dabei um Flexibilität, die in 15 Minuten für 15 Minuten abrufbar ist.

Als zugrundeliegende Zeitreihe für die Prognose der Strompreise dienen in 15-Minuten-Blöcken gehandelte kontinuierliche Strompreise des Intraday-Handels von 14 Wochentagen, welche in ABBILDUNG 3 dargestellt sind. In beiden Zeitreihen liegen 96 Zeitschritte pro Tag vor.

Es wurden jeweils für den letzten Tag der Zeitreihe 96 Prognosen, ausgehend vom jeweils vorherigen Zeitschritt angefertigt. Der Prognosehorizont betrug acht bzw. zehn Zeitschritte. Der MAPE bzw. der MAE wurde für jeden Prognosehorizont berechnet.

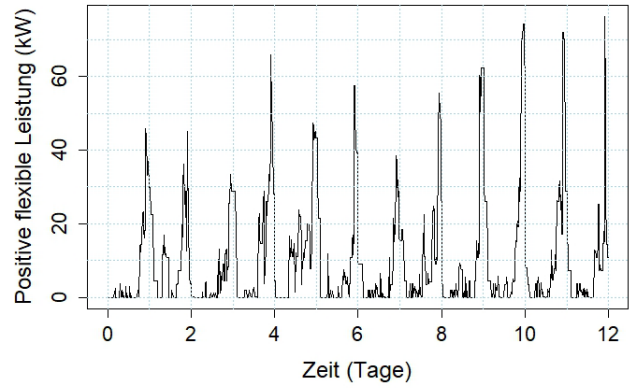


ABBILDUNG 2: DIE AGGREGIERTE FLEXIBILITÄT VON 50 HAUSHALTEN.




ABBILDUNG 3: DER KONTINUIERLICHE STROMPREIS.

V. ERGEBNISSE

Die Auswertung der Prognosen ergab, dass die diskutierten Modelle sehr eingeschränkt für die gewünschten Prognosezwecke verwendet werden können. Die Betrachtung des MAPEs bzw. MAEs ließ den Schluss zu, dass die Modelle nicht in der Lage sind, konkrete Werte zu prognostizieren. Der Vergleich der Prognosen über einen Zeitschritt mit der naiven Prognose ergab, dass die Modelle nicht wesentlich besser sind als die naive Prognose. Die Prognosen der abrufbaren Flexibilität der Modelle wurden weiterhin mit den Prognosen des EMS verglichen, diese waren den Prognosen der Modelle überlegen.

Die Modelle waren in der Lage, Trends mit einer gewissen Sicherheit zu prognostizieren. Dies gelang am besten bei den kontinuierlichen Strompreisen mit Hilfe des ARIMA-Modells. Mittels ARIMA konnte der Trend des kontinuierlichen Strompreises über sämtliche Prognosehorizonte durchschnittlich in 64,44 % aller Fälle richtig prognostiziert werden. In TABELLE I sind sämtliche Ergebnisse der Trendprognosen des kontinuierlichen Strompreises mittels ARIMA dargestellt.

TABELLE I: AUSWERTUNG DER PROGNOSE DER KONTINUIERLICHEN STROMPREISE MIT HILFE DES ENTWICKELTEN ARIMA MODELLS.

Prognosehorizont	Trend richtig	In Prozent	Stichprobengröße
T+1	61	63,54	96
T+2	55	57,89	95
T+3	57	60,64	94
T+4	60	64,52	93
T+5	59	64,13	92
T+6	64	70,33	91
T+7	59	65,56	90
T+8	54	60,67	89
T+9	60	68,18	88
T+10	60	69	87

In den meisten Fällen gelang es, Modelle mit einer befriedigenden Güte anzupassen. Insbesondere bei auf die Strompreise angepassten ARIMA-Modellen ergab die Betrachtung der Residuen gelegentlich, dass in diesen noch Informationen enthalten waren. Weiterhin wurden mittels R auf nahezu identische Zeitreihen gänzlich unterschiedliche Modelle angepasst, was darauf schließen lässt, dass die Güte der gebildeten Modelle nicht optimal war.

Insgesamt legen die Ergebnisse den Schluss nahe, dass die Modelle nur sehr begrenzt dazu in der Lage sind, einen Algorithmus zum Angebot von aggregierter Flexibilität an Strommärkten zu unterstützen.

VI. ALGORITHMUS

Ein Algorithmus mit dem Ziel, den Ertrag für die Mehrheit der betrachteten Haushalte zu aggregieren, kann sich nicht nur auf die Prognosen der diskutierten Modelle stützen, da deren Prognosequalität zu gering ist. Eine Berücksichtigung weiterer Kenngrößen ist erforderlich.

Die Betrachtung des durchschnittlich zu erwartenden Ertrags ergab eine zeitliche Abhängigkeit. Dieser wurde durch die Multiplikation der durchschnittlichen Strompreise der beobachteten 14 Tage mit den durchschnittlich abrufbaren Flexibilitäten der beobachteten zwölf Tage bestimmt. Der durchschnittliche Ertrag ist in ABBILDUNG 4 dargestellt. Da der realisierbare Ertrag von der jeweiligen Tageszeit abhängt, kann der Algorithmus sich an zuvor definierten Perioden orientieren.

Weiterhin ergab die Betrachtung der Zeitreihen, dass es insbesondere bei den kontinuierlichen Strompreisen zu starken „Ausreißern“ kommt. Der Algorithmus benötigt einen Mechanismus, um diese zu erkennen, um von möglichen hohen Erträgen zu untypischen Zeiten profitieren zu können.




ABBILDUNG 4: DER DURCHSCHNITTLICH MÖGLICHE ERTRAG.

A. Funktionsweise

Die wesentlichen Merkmale des entwickelten Algorithmus werden im Folgenden umrissen. Grundsätzlich orientiert sich der Algorithmus an zuvor definierten Perioden und wird bis auf den folgenden Schritt nur innerhalb ausgewählter Perioden tätig. Der Algorithmus prüft zunächst in jedem Zeitschritt auf „Ausreißer“ und prüft, ob der mögliche Ertrag größer als ein definierter minimaler Ertrag ist.

Innerhalb der ausgewählten Perioden löst der Algorithmus ein Optimierungsproblem. Die aggregierte Flexibilität soll zum Zeitpunkt des prognostizierten Maximums angeboten werden, sofern dieses größer als der Mindestertrag ist. Bis dieser Zeitpunkt erreicht wird, prüft er kontinuierlich, ob ein noch höherer Ertrag möglich ist. Ist dies der Fall, wird entschieden, dass zu diesem neuen Zeitpunkt Flexibilität angeboten werden soll.

Ist ein solcher Zeitpunkt erreicht, wird die aggregierte Flexibilität nur angeboten, wenn der Ertrag größer als der Minimalertrag ist.

Der Algorithmus verwendet für die Prognose der abrufbaren Flexibilität die Prognosen des Energiemanagementsystems. Diese haben sich als wesentlich genauer als die Prognosen der Modelle erwiesen. Daraus resultiert jedoch ein geringer Prognosehorizont. Für die Prognose der Strompreise stützt sich der Algorithmus auf die Trendprognosen des ARIMA-Modells. Diese werden lediglich als Indikator verwendet. Wird ein positiver Trend prognostiziert, wird der aktuelle Strompreis mit einem Faktor größer 1 multipliziert, und umgekehrt.

Das Ablaufdiagramm des Algorithmus ist in ABBILDUNG 5 dargestellt.

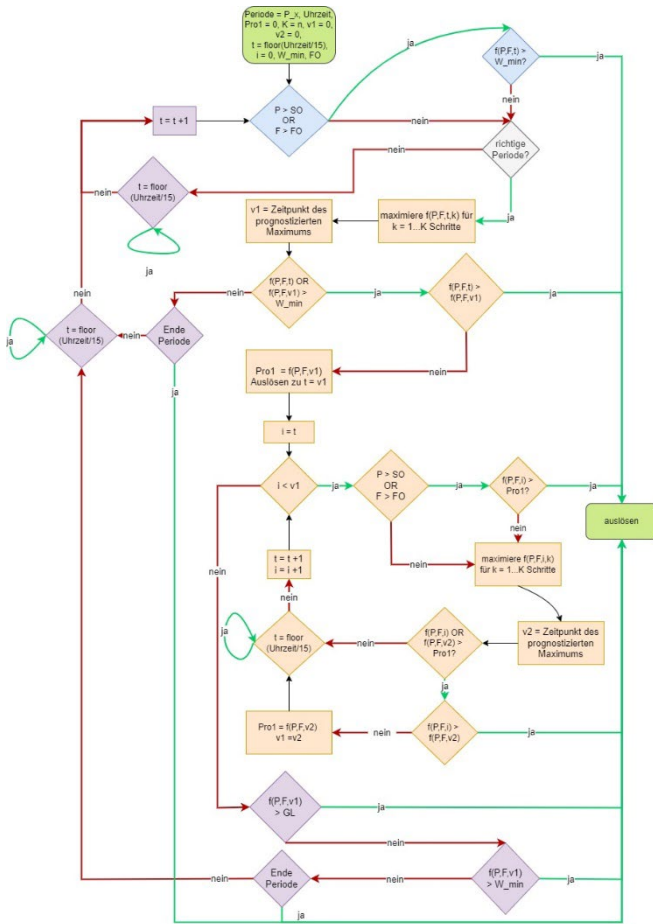


ABBILDUNG 5: DAS ABLAUFDIAGRAMM DES ALGORITHMUS.

Der Algorithmus benötigt weiterhin eine Vielzahl von Grenzen, wie etwa den Mindestertrag, der generiert werden soll, oder eine Grenze, ab der ein Strompreis als „Ausreißer“ gilt. Diese Grenzen ergeben sich gemäß dem Prinzip der Bollinger-Bänder, dargestellt in Gleichung 17 – 19, dynamisch aus vergangenen Werten. Dazu müssen die vorliegenden Werte annähernd normalverteilt sein. Die Grenzen ergeben sich aus dem gleitenden Durchschnitt vergangener Werte, auf den die mit dem Faktor k multiplizierte Standardabweichung addiert bzw. von dem sie subtrahiert wird. Durch den Faktor k kann bei einer vorliegenden Normalverteilung bestimmt werden, wie viele Werte prozentual außerhalb der Grenzen liegen.

$$BB_{\text{mitte}}(t) = m^{(n)}(t) = \frac{1}{n} \sum_{i=0}^{n-1} x(t-i) \quad (17)$$

$$BB_{\text{oben}}(t) = BB_{\text{mitte}}(t) + k\sigma \quad (18)$$

$$BB_{\text{unten}}(t) = BB_{\text{mitte}}(t) - k\sigma \quad (19)$$

Die Wahl der Perioden orientierte sich am durchschnittlichen Verlauf des Ertrages und am Prognosehorizont. Die Perioden wurden jeweils so gewählt, dass die Höhe des möglichen Ertrags innerhalb der Perioden relativ homogen bleibt. Somit wird auch eine falsche Entscheidung aufgrund einer falschen Prognose nicht zu einem gänzlich anderen Ertrag führen. Weiterhin betrug die Periodenlänge nie mehr als das Doppelte des Prognosehorizonts.

B. Versuch

In einem durchgeführten Versuch war der Algorithmus in der Lage, in den betrachteten Perioden den bestmöglichen Zeitpunkt auszuwählen. Es wurden zwei Perioden ausgewählt, in einer dieser Perioden lag der höchstmögliche Ertrag des Tages. In beiden Perioden wäre zum jeweiligen Periodenmaximum Flexibilität angeboten worden, welches in einem von zwei Fällen der letzte Zeitpunkt innerhalb der Periode war.

Der Versuch hat gezeigt, wie wichtig die Wahl der Grenzen insbesondere des minimalen Ertrags ist. Die gewählte Methode, um den Mindestertrag zu bestimmen, scheint geeignet, da dieser Wert im Ganzen dreimal überschritten wurde. Der erste Wert, der diesen überschritt, war bereits das Perioden- und Tagesmaximum. Im ungünstigsten Fall (bei einer anderen Reihenfolge der Maxima) wäre jedoch immer noch zum dritthöchsten Ertrag des Tages Flexibilität angeboten worden.

Der Mindestertrag wurde in der ersten betrachteten Periode nie erreicht, sodass nur durch das Erreichen des Periodenendes automatisch Flexibilität angeboten worden wäre. Dies verdeutlicht, dass die Wahl der Perioden ebenfalls von hoher Bedeutung für den Erfolg des Algorithmus ist.

Aufgrund des erfolgten Versuchs lässt sich sagen, dass es möglich ist, gezielt einen möglichst hohen Ertrag für die Summe der betrachteten Haushalte zu generieren.

VII. DISKUSSION

Ziel dieser Arbeit war es, einen Algorithmus bzw. eine Heuristik zu entwickeln, auf dessen Grundlage Aggregatorentscheidungen zum Angebot von Flexibilitäten an Strommärkten ermöglicht werden. Ein Aggregator sollte dazu befähigt werden, den maximalen Nutzen bzw. den höchstmöglichen Ertrag für eine Mehrheit der Haushalte zu generieren.

Um eine validierte Entscheidung treffen zu können, müssen vergangene, aktuelle und vor allem zukünftige Werte vom Aggregator in dessen Entscheidung einbezogen werden. Mathematische Modelle wie ARIMA und TBATS können mit geringem Aufwand aufgestellt werden, bieten jedoch eine geringe Prognosequalität im Vergleich zu KI oder hybriden Methoden. Dies lässt sich darauf zurückführen, dass die Modelle an eine beobachtete Zeitreihe angepasst werden und zu Prognosezwecken auf vergangene Werte zurückgreifen, um zukünftige Werte zu prognostizieren. Aktuelle äußere Einflüsse wie beispielsweise die aktuelle Einspeiseleistung Erneuerbarer Energien werden nicht berücksichtigt. Insbesondere die kontinuierlichen Strompreise sind durch ein starkes Rauschen geprägt, welches zumindest teilweise auf äußere Einflüsse zurückgeführt werden kann.

Es wurde untersucht, inwiefern ARIMA und TBATS dennoch Entscheidungen eines Aggregators unterstützen können. Die Ergebnisse lassen darauf schließen, dass besagte Modelle, insbesondere auf Strompreise angepasste ARIMA-Modelle, in der Lage sind, Trends zu erkennen.

Die Prognosefähigkeit des EMS hingegen war ausreichend, um zumindest kurzfristig genaue Aussagen über die aggregierte abrufbare Flexibilität treffen zu können. Für die Prognose von Strompreisen musste auf mittels ARIMA prognostizierte Trendprognosen zurückgegriffen werden.

Es ist gelungen, einen Algorithmus zu entwickeln, der trotz der diskutierten Einschränkungen in der Lage ist, einen relativ hohen Ertrag für die Mehrheit der betrachteten Haushalte zu erzielen. In einem durchgeführten Versuch traf der Algorithmus in beiden betrachteten Perioden die Entscheidung, Flexibilität für den jeweils höchstmöglichen Ertrag anzubieten.

Diese Arbeit hat demnach gezeigt, dass Flexibilitätspotentiale durch einen Aggregator erfolgreich ausgenutzt werden können und dieser in der Lage sein kann, den Ertrag für bereitgestellte aggregierte Haushaltslasten zu optimieren. Der auf diese Weise realisierte Ertrag kann Verbrauchern als monetärer Anreiz dienen. Dennoch muss in diesem Bereich noch viel geforscht werden.

Die in dieser Arbeit beschriebene Systematik bietet die Möglichkeit, im Rahmen von weiteren Arbeiten weiter getestet, ausgebaut und verbessert zu werden.

Es bietet sich weitere Forschung auf dem Gebiet der Prognosen an. Mittels dynamischer Prognosen, welche neben den vergangenen Preisen auch andere Variablen einbeziehen, könnte die Prognosefähigkeit höchstwahrscheinlich gesteigert werden. Dies könnten aktuelle Umweltzustände wie beispielsweise die Sonneneinstrahlung oder Einspeiseleistung sein. Möglicherweise bieten Neuronale Netze eine geeignete Plattform, um die genannten Punkte umzusetzen.

LITERATUR

- [1] *Flexibilität im Stromversorgungssystem: Bestandsaufnahme, Hemmnisse und Ansätze zur verbesserten Erschließung von Flexibilität.* [Online]. Verfügbar unter: Bestandsaufnahme, Hemmnisse und Ansätze (Zugriff am: 8. August 2022).
- [2] C. Zöphel und T. Müller, Hg., *Flexibilitätsoptionen am Strommarkt: Eine Analyse zu Hemmnissen und Erlösmöglichkeiten*, 2016.
- [3] T. Müller und C. Brunner, *Flexibilitätsoptionen zur Systemintegration erneuerbarer Energien im Kostenvergleich.* Verfügbar unter: https://www.researchgate.net/publication/317359058_Flexibilitatsoptionen_zur_Systemintegration_erneuerbarer_Energien_im_Kostenvergleich.
- [4] T. Künzel, F. Klumpp und A. Weidlich, *Modellgestützte Analyse der Bereitstellung von Flexibilität auf dem Strom- und Regelleistungsmarkt in Deutschland.* Verfügbar unter: https://www.researchgate.net/publication/321052010_Modellgestuetzte_Analyse_der_Bereitstellung_von_Flexibilitat_auf_dem_Strom-und_Regelleistungsmarkt_in_Deutschland.
- [5] A. Liebe, Wissner und M., *Der flexible Verbraucher – Potenziale zur Lastverlagerung im Haushaltsbereich.* [Online]. Verfügbar unter: <https://um.baden-wuerttemberg.de/de/service/publikation/did/studien-der-flexible-verbraucher-potenziale-zur-lastverlagerung-im-haushaltsbereich/> (Zugriff am: 18. August 2022).
- [6] F. Heider, A. Jahic, M. Plenz und D. Schulz, „Extended Residential Power Management Interface for Flexibility Communication and Uncertainty Reduction for Flexibility System Operators“, *Energies*, Jg. 15, Nr. 4, S. 1257, 2022, doi: 10.3390/en15041257.
- [7] M. Laskowski, „Die Aggregation von Flexibilitäten zur Integration Erneuerbarer Energien“. Dortmund, 2013.
- [8] L. Bank, „Energieflexibel in die Zukunft – Wie Fabriken zum Gelingen der Energiewende beitragen können“, 2021.
- [9] P. Bento, H. Nunes, J. Pombo, M. Calado und S. Mariano, „Daily Operation Optimization of a Hybrid Energy System Considering a Short-Term Electricity Price Forecast Scheme“, *Energies*, Jg. 12, Nr. 5, S. 924, 2019, doi: 10.3390/en12050924.
- [10] *2016 12th World Congress on Intelligent Control and Automation (WCICA)*. IEEE: IEEE, Jun. 2016 - Jun. 2016.
- [11] A. Veit, C. Goebel, R. Tidke, C. Doblander und H.-A. Jacobsen, „Household electricity demand forecasting“ in *e-Energy '14: The Fifth International Conference on Future Energy Systems*, Cambridge United Kingdom, 06112014, S. 233–234, doi: 10.1145/2602044.2602082.
- [12] D. R. Graeber, *Handel mit Strom aus erneuerbaren Energien*. Wiesbaden: Springer Fachmedien Wiesbaden, 2014.
- [13] F. J. Matzen und R. Tesch, *Industrielle Energiestrategie*. Wiesbaden: Springer Fachmedien Wiesbaden, 2017.
- [14] next, *Was ist der Intraday-Handel?* [Online]. Verfügbar unter: <https://www.next-kraftwerke.de/wissen/intraday-handel/#:~:text=Ein%20Unterschied%20zum%20Day%2DAhead,werden%20die%20Preise%20im%20kontinuierlichen> (Zugriff am: 5. Juli 2022).
- [15] E. Avdevcicus, F. Heider, M. Eskander und D. Schulz, *Smart Grid Residential Load Modeling for Real-time Applications*. NEIS 2021, Conference on Sustainable Energy Supply and Energy Storage Systems.
- [16] W. Zucchini und O. Nenadic, *Zeitreihenanalyse: Teil II: Lineare Zeitreihenmodelle.* [Online]. Verfügbar unter: https://www.uni-goettingen.de/de/document/download/bced8d2cf092e3487839c365955c85f2.pdf/ZRSkript_Teil2_Okt09.pdf.
- [17] K. Backhaus, B. Erichson, W. Plinke und R. Weiber, *Multivariate Analysemethoden*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016.
- [18] J. Vogel, *Prognose von Zeitreihen*. Wiesbaden: Springer Fachmedien Wiesbaden, 2015.
- [19] J. W. Taylor, „Triple seasonal methods for short-term electricity demand forecasting“, *European Journal of Operational Research*, Jg. 204, Nr. 1, S. 139–152, 2010, doi: 10.1016/j.ejor.2009.10.003.
- [20] A. de Livera, *Automatic forecasting with a modified exponential smoothing state space framework.* [Online]. Verfügbar unter: https://www.researchgate.net/publication/228381426_Automatic_forcasting_with_a_modified_exponential_smoothing_state_space_framework (Zugriff am: 23. Juli 2022).
- [21] A. de Livera, R. Hyndman und Snyder R, *Forecasting time series with complex seasonal patterns using exponential smoothing.* Working Paper. [Online]. Verfügbar unter: <https://robjhyndman.com/papers/ComplexSeasonality.pdf>.
- [22] *Bayesian Forecasting and Dynamic Models*. New York: Springer-Verlag, 1997.
- [23] D. Obszelka und A. Baierl, *Statistisches Programmieren mit R*. Wiesbaden: Springer Fachmedien Wiesbaden, 2020.
- [24] R. J. Hyndman und Y. Khandakar, „Automatic Time Series Forecasting: The forecast Package for R“, *J. Stat. Soft.*, Jg. 27, Nr. 3, 2008, doi: 10.18637/jss.v027.i03.
- [25] Hyndman, R.J., & Athanasopoulos, G., *Forecasting: Principles and Practice.* [Online]. Verfügbar unter: <https://otexts.com/fpp2/index.html>