

Methoden

Stefan Klaiber*, Fabian Bauer und Peter Bretschneider

Verbesserung der Netzverlustprognose für Energieübertragungsnetze

Improvement of grid loss forecast for energy transmission grids

<https://doi.org/10.1515/auto-2020-0076>

Empfangen 2. Mai 2020; angenommen 29. Juni 2020

Zusammenfassung: Bei der Energieübertragung entstehen Netzverluste in den Leitungen und Betriebsmitteln des elektrischen Energiesystems. Die Höhe der Netzverluste ist sowohl von der Netzlast als auch von zahlreichen weiteren Einflussgrößen abhängig. Einen besonderen Einfluss hat dabei die fluktuierende und größtenteils verbrauchsferne Erzeugung durch erneuerbare Energien. Die Übertragungsnetzbetreiber müssen die elektrische Energie zum Ausgleich der Netzverluste im Voraus beschaffen. Um die benötigte Ausgleichsenergie möglichst kostenminimal einzukaufen, ist eine genaue Prognose der Netzverluste notwendig. Im Rahmen des vorliegenden Beitrags wird ein Verfahren vorgestellt, das für die Prognose der Netzverluste im Übertragungsnetz der 50Hertz Transmission GmbH zum Einsatz kommt. Als Modellansatz der Prognosemethode werden Künstliche Neuronale Netze verwendet. Das als Ergebnis der Arbeiten entwickelte Modell für die Netzverlustprognose steigert die Prognosegüte im Vergleich zum bisherigen Modell um sieben Prozent und befindet sich bei 50Hertz seit Juni 2019 im operativen Einsatz.

Schlagwörter: Netzverluste, Zeitreihenprognose, Künstliche Neuronale Netze

Abstract: During energy transmission, grid losses occur in the lines and equipment of the electrical energy system. The extent of the grid losses depends both on the grid load and on numerous other influencing variables. The fluctuating and largely consumption-distant-related generation by renewable energies has a special influence. The trans-

***Korrespondenzautor:** Stefan Klaiber, Fraunhofer IOSB, IOSB-AST Ilmenau, Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung, Am Vogelherd 90, 98693 Ilmenau, Germany, E-Mail: stefan.klaiber@iosb-ast.fraunhofer.de

Fabian Bauer, Peter Bretschneider, Technische Universität Ilmenau, Fakultät für Elektrotechnik und Informationstechnik, Fachgebiet Energieeinsatzoptimierung, Gustav-Kirchhoff-Str. 5, 98693 Ilmenau, Germany, E-Mails: fabian.bauer@tu-ilmenau.de, peter.bretschneider@tu-ilmenau.de

mission system operators have to procure the electrical energy to compensate for the grid losses in advance. In order to purchase the required balancing energy at the lowest possible cost, a precise forecast of the grid losses is necessary. In this paper a method is presented which is used for the forecast of the grid losses in the transmission grid of 50Hertz Transmission GmbH. Artificial neural networks are used as a model approach for the prognosis method. The model developed as a result of the work for the grid loss forecast increases the forecast quality by seven percent compared to the previous model and has been in operational use at 50Hertz since June 2019.

Keywords: grid losses, time series forecast, artificial neural networks

1 Einleitung

Die elektrischen Netzverluste entstehen bei der Übertragung elektrischer Energie und sind im Verantwortungsbereich des Netzbetriebs. Sie sind Unbundling-konform über einen transparenten Einkaufsprozess am Energiemarkt zu beschaffen. Zur Minimierung der dabei anfallenden Kosten spielt die exakte Vorhersage der Netzverluste eine sehr wichtige Rolle und ist somit Gegenstand der wissenschaftlichen Untersuchungen.

Die elektrischen Netzverluste treten in den Übertragungsleitungen, Transformatoren sowie anderen Systemelementen auf und sind u. a. von der Spannung, Stromstärke sowie Transportstrecke abhängig. Insbesondere die Distanzen, über die der Strom transportiert werden muss, vergrößern sich im Zuge der Energiewende aufgrund der dezentralen Einspeisung. So ist es notwendig, die Energie zum Zeitpunkt des Bedarfs teilweise über große Distanzen mit dementsprechend höheren Netzverlusten zu transportieren.

In Deutschland sind die Betreiber von Übertragungs- und Verteilnetzen für Elektrizität nach dem Energiewirtschaftsgesetz [1] und der Stromnetzzugangsverordnung [2] dazu verpflichtet, die Beschaffung von Energie zum Aus-

gleich der Netzverluste in einem transparenten, marktorientierten und diskriminierungsfreien Verfahren durchzuführen. Die Bundesnetzagentur (BNetzA) schreibt für die Beschaffung der auftretenden Verluste im elektrischen Übertragungsnetz ein zweistufiges Verfahren vor. Gemäß der Festlegung der BNetzA erfolgt eine Unterteilung in langfristig prognostizierte (Langfristkomponente) und kurzfristig prognostizierte Netzverluste (Kurzfristkomponente). [3]

Die Beschaffung auf Basis der Langfristprognose erfolgt beispielsweise über Terminprodukte mit börslichen Produkten an der European Energy Exchange (EEX) und in offenen Ausschreibungen. Die Netzbetreiber greifen dabei aufgrund von volatilen Preisen auf verschiedene bzw. kombinierte Beschaffungsstrategien zurück, um das Risiko ungünstiger Preise bei Handelsabschluss zu reduzieren. Als Kurzfristkomponente wird die Abweichung der Kurzfristprognose zur Langfristprognose der Netzverluste verstanden. Die Kurzfristkomponente dient folglich zur Anpassung der bereits beschafften elektrischen Verlustenergie an die tatsächlich benötigte. Durch eine Day-Ahead-Prognose werden jeweils am Vortag des Liefertages die erwarteten Netzverluste aktualisiert und die zum Ausgleich benötigte elektrische Energie am Day-Ahead-Markt hinzugekauft oder verkauft. [3, 4]

Aufgrund der begrenzten Prognostizierbarkeit des langfristigen Netzverlustverlaufs ist die Genauigkeit der kurzfristigen Prognose von entscheidender Bedeutung. Eine exakte Prognose der Netzverluste trägt dazu bei, die benötigte Regelleistung¹ zu reduzieren und damit die Systemstabilität und -sicherheit zu erhöhen.

Die etablierten Methoden zur Zeitreihenvorhersage bei der Netzverlustprognose unterteilen sich in deterministische, lineare stochastische und nichtlineare stochastische Zeitreihenmodelle. Jüngst wurde von Bothor in [4] ein Prognoseverfahren für Netzverluste, basierend auf linear stochastischen Zeitreihenmodellen, entwickelt. Neben der erfolgreichen Etablierung eines saisonalen Autoregressive Moving-Average-Modells mit exogenen Regressoren, weist der Autor in seiner Arbeit darauf hin, dass Künstliche Neuronale Netze (KNN) insbesondere bei nichtlinearen Zusammenhängen verbesserte Prognoseergebnisse erzielen können. Zusätzlich steigt durch die Digitalisierung der Energiewirtschaft die Anzahl der messtechnisch erfassten Energiezeitreihen und exogenen Einflussgrößen signifikant an. Damit verbunden ergibt sich

die Möglichkeit, aus der Vielzahl an Daten verbesserte Modelle zu identifizieren und nutzbar zu machen. Maschinelles Lernen ist eine Anwendung der künstlichen Intelligenz, die Systeme in die Lage versetzt, aus Daten selbstständig zu lernen. Insbesondere bei vielen Untersuchungsgrößen mit nichtlinearen oder auch unbekanntem Abhängigkeiten versprechen die Verfahren des maschinellen Lernens einen entscheidenden Vorteil gegenüber bestehenden Methoden. Im vorliegenden Beitrag wird ein Prognosemodell, basierend auf KNN, vorgestellt, das für die Prognose der Netzverluste im Übertragungsnetz der Regelzone der 50Hertz Transmission GmbH zum Einsatz kommt [5] und gegenüber dem Einsatz etablierter Methoden eine Steigerung der Prognosegüte aufweist. Dazu werden im Abschnitt 2 zunächst die Entstehung der Netzverluste und die Strukturmerkmale erläutert. Im Abschnitt 3 erfolgt die Einführung in die untersuchten Modellansätze. Die Abschnitte 4 und 5 zeigen die Modellierung der Prognosemethode und die Modellvalidierung. Abschließend fasst der Abschnitt 6 die Untersuchungsergebnisse zusammen und gibt einen Ausblick.

2 Netzverluste und Strukturmerkmale

Die Netzverluste errechnen sich aus der Differenz zwischen der eingespeisten und entnommenen elektrischen Energie eines Netzes. Bei der Übertragung elektrischer Energie im Netz entstehen aufgrund von verschiedenen physikalischen Prozessen Verluste in Netzkomponenten und Betriebsmitteln [6]. Diese Verluste treten beispielsweise aufgrund der Ohmschen Widerstände der Leitung, Ableitungen über Isolatoren, Korona- und Eisenverluste auf. Prinzipiell lassen sich die Netzverluste nach ihrer Abhängigkeit in drei Kategorien unterteilen, die in der nachfolgenden Tabelle aufgeführt sind (vgl. Tab. 1).

Die Stromwärmeverluste, auch Joulesche Verluste genannt, zählen zu den lastabhängigen Verlusten. Diese stellen den Hauptanteil an Verlusten dar und sind vom Energiedurchsatz abhängig. Stromwärmeverluste entstehen in elektrischen Leitern aufgrund der Kollision der bewegten Ladungsträger mit den Atomen des Leiters. Durch diese elastischen Stöße werden die Atome im Metallgitter des Leiters in Schwingung versetzt und es entstehen Wärmeverluste. [6]

Zu den lastunabhängigen Verlusten zählen die Ableitungs- und Magnetisierungsverluste sowie der Eigenverbrauch der technischen Einrichtungen für den

¹ Als Regelleistung oder Regelenergie bezeichnet man die Leistung bzw. Energie, die ein Netzbetreiber aufwenden muss, um unvorhergesehene Leistungsungleichgewichte in seinem Stromnetz auszugleichen.

Tab. 1: Einteilung der Netzverluste nach Abhängigkeit.

Lastabhängig	Lastunabhängig	Nichttechnisch
Stromwärmeverluste (Ohmsche Verluste in Leitungen, Kabeln, Klemmstellen, Sicherungen)	Ableitungsverluste: – Isolationsverluste – Koronaverluste – Dielektrische Verluste Magnetisierungsverluste Betriebseigenverbrauch	Stromdiebstahl Fehlerhafte Mess- und Zähleinrichtungen

Netzbetrieb. Die Ableitungsverluste in Form von Koronaverlusten, Verlusten im Dielektrikum und an Isolatoren machen gegenüber den Gesamtverlusten nur einen geringen Anteil aus. Die Koronaverluste entstehen an Freileitungen, wenn die Stärke des elektrischen Feldes die elektrische Festigkeit der Luft übersteigt. Infolgedessen kommt es zu Teilentladungen in der Luft. Die Isolationsverluste sind umgebungs- und witterungsabhängig und entstehen durch Verunreinigungen und Ablagerungen auf Isolatoren, die zu Kriechströmen und folglich zu Verlusten führen. Die dielektrischen Verluste in Kabeln und Kondensatoren ergeben sich aufgrund von Polarisierungseffekten in den Isolierstoffen. Ebenfalls zu den lastunabhängigen Verlusten zählen die Magnetisierungsverluste, die in Form von Hysterese- und Wirbelstromverlusten in Transformatoren auftreten. Zu den nichttechnischen Verlusten zählen z. B. Stromdiebstahl und Datenverarbeitungsfehler. [4, 6–9]

Die 50Hertz Transmission GmbH ist der zuständige Übertragungsnetzbetreiber für den Norden und Osten Deutschlands. Das Übertragungsnetz der 50Hertz Regelzone weist nach [10] die nachfolgenden Strukturmerkmale auf. Das Leitungsnetz umfasst eine Länge von 10.300 km. Im Jahr 2018 wurden 117 TWh über das Netz transportiert, wobei 2,51 TWh Netzverluste entstanden. Die Kosten dafür beliefen sich auf rund 70 Millionen Euro. In der Höchstspannungsebene betragen die durchschnittlichen Verluste 239,7 MW und in der Umspannung 46,3 MW. Mit einem rechnerischen Anteil von 59,3% stellen die erneuerbaren Energien einen besonderen Faktor im Netzgebiet von 50Hertz dar.

Aufgrund geografischer Vorteile findet ein Großteil der Windenergieeinspeisung im Norden von Deutschland statt, wobei sich die Regionen mit hohem Energiebedarf überwiegend in Süddeutschland befinden. Das führt zu hohen Energieflüssen in Nord-Süd-Richtung. Damit bilden Windenergieeinspeisung und Transite² die Haupteinfluss-

größen in Bezug auf die Netzverluste. Aufgrund dessen ist bei der Modellierung der Netzverlustprognose eine besondere Analyse und Beachtung der exogenen Einflussgrößen notwendig.

3 Untersuchte Modellansätze

3.1 Lineare deterministische und stochastische Zeitreihenmodelle

Zur Beschreibung von Zeitreihen wird häufig auf den universellen Ansatz des Komponentenmodells zurückgegriffen, welches deterministische und stochastische Zeitreihenanteile kombiniert [17].

Deterministische Zeitreihenmodelle sind Modellansätze, die systematische Komponenten einer Zeitreihe als deterministische Funktionen von der Zeit abbilden und eine analytische Darstellung von Signalverläufen ermöglichen. Bekannte Vertreter der deterministischen Zeitreihenmodelle sind das Polynommodell und das periodische Modell. Die Parameterschätzung erfolgt i. d. R. mittels Regression. Die Methoden zählen zu den robusten Verfahren und gelten als universell einsetzbare Beschreibungsformen für Zeitreihen. [11]

Die linearen stochastischen Zeitreihenmodelle sind die Grundlage zahlreicher Prognosemodelle und stellen eine der wichtigsten Modellklassen bezogen auf die Zeitreihenprognose dar. Linear stochastische Zeitreihenmodelle bilden das Verhalten zufälliger Prozesse ab, indem die inneren Zusammenhänge von Zeitreihen auf Basis linearer stochastischer Prozesse beschrieben werden. Im Laufe der Zeit wurden die Autoregressive (AR), Moving Average (MA), Autoregressive Moving Average (ARMA), Autoregressive Integrated Moving Average (ARIMA) sowie Autoregressive Moving Average Exogenous (ARMAX) Verfahren entwickelt und in die Praxis umgesetzt. Interessierte werden an [12, 13] und [17] verwiesen. Insbesondere im Bereich der Energiezeitreihenvorhersage sind umfassende Entwicklungen im Bereich der ARMA und ARIMAX-

² Transite sind Durchleitungen von Energie durch das Übertragungsnetz einer dazwischenliegenden Regelzone.

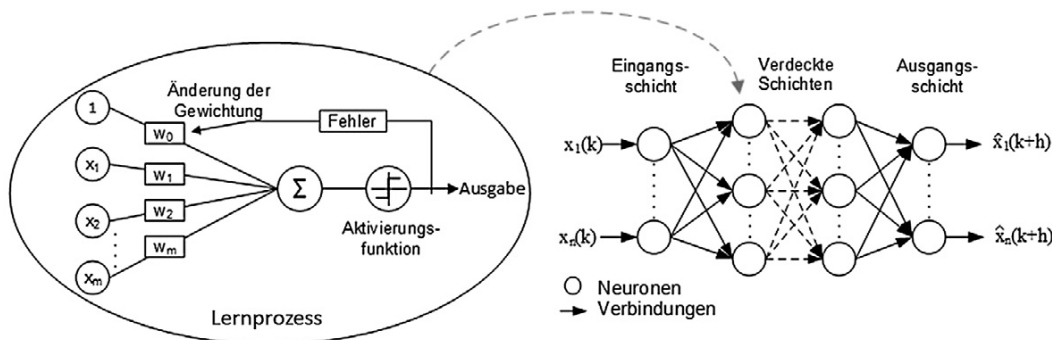


Abb. 1: Künstliches neuronales Netz in Anlehnung an [14].

Modelle durchgeführt und umgesetzt worden, wie zuletzt in [4] mit der Entwicklung eines Seasonal Autoregressive Integrated Moving Average (SARIMA) Modells zur Netzverlustprognose. Das ARMA-Modell bildet einen zugrundeliegenden Modellansatz für die durchgeführten Untersuchungen und setzt sich aus einem AR- und einem MA-Modell zusammen. Nachfolgend sind die mathematischen Beschreibungen der grundlegenden AR- und MA-Prozesse aufgeführt.

AR(p)-Modell (aurergressive)

$$x[k] = \sum_{i=1}^p [a_i \cdot x[k-i]] + \varepsilon[k] \quad (1)$$

mit: $\varepsilon[k]$ – Zeitreihe weißen Rauschens zum Zeitindex k ,
 $x[k]$ – zeitdiskrete Zeitreihe zum Zeitindex k ,
 p – Ordnung des AR-Modells und
 a_i – Modellparameter.

MA(q)-Modell (moving average)

$$x[k] = \sum_{i=1}^q [b_i \cdot \varepsilon[k-i]] \quad (2)$$

mit: $\varepsilon[k]$ – Zeitreihe weißen Rauschens zum Zeitindex k ,
 $x[k]$ – zeitdiskrete Zeitreihe zum Zeitindex k ,
 q – Ordnung des MA-Modells und
 b_i – Modellparameter.

3.2 Künstliche Neuronale Netze

Künstliche Neuronale Netze sind informationsverarbeitende Systeme, deren Struktur und Funktionsweise Analogien zum menschlichen Gehirn aufweisen. Sie gehören zu den maschinellen Lernverfahren. Die technische Adaption beruht dabei auf der Nachbildung der biologischen Nervenzellen und den dazugehörigen neuronalen Verbindungen. Die Neuronen bilden die funktionellen Grundeinheiten, sind in mehreren Schichten angeordnet und miteinander verbunden (s. Abb. 1). Die Schichten unterteilen sich in

die Eingangsschicht, verdeckte Schichten und Ausgangsschicht. Die Neuronen einer Schicht sind mit den Neuronen der vorherigen und der nachfolgenden Schicht verbunden. Den Verbindungen zwischen den Neuronen werden Gewichte zugeordnet, welche die Relevanz einer Verbindung kennzeichnen. Die angelegten Signale der Eingangsschicht werden an die direkt verbundenen Knoten weitergegeben. In den Knoten werden die Gewichte aufsummiert, an eine Aktivierungsfunktion übergeben und der Ausgabewert berechnet. Die Informationsverarbeitung erfolgt somit in den verdeckten Schichten von der Eingangszur Ausgangsschicht. Dabei sind die Anzahl der verdeckten Schichten, die Anzahl der enthaltenen Neuronen und die verwendete Aktivierungsfunktion freie Parameter bei der Konfiguration des KNN.

Für das Trainieren der neuronalen Netzstruktur, also dem Ändern der gewichteten Verbindungen, werden Lernverfahren verwendet. Eines der bekanntesten Verfahren ist der Backpropagation-Algorithmus. Dabei erfolgt die Korrektur der Netzgewichte w mittels Gradientenabstiegsverfahren zur Fehlerminimierung. Durch das trainierte Netz erfolgt die Abbildung des Prognosewertes $\hat{x}_n(k+h)$ in der Ausgangsschicht. Für tiefere Erläuterungen wird auf [14] und [15] verwiesen.

4 Modellierung

Das Ziel des vorliegenden Beitrags ist es, eine Prognosemethode für die Vorhersage der Netzverluste als Grundlage der Day-Ahead-Beschaffung der Verlustleistung im Übertragungsnetz von 50 Hertz zu entwickeln. Das zu entwickelnde Modell soll das Ein- und Ausgangsverhalten bei der Entstehung von Netzverlusten mit einem hinsichtlich der Prognosequalität geeigneten Modellansatz wiedergeben. Das Vorgehen für den Entwurf des Prognosemodells orientiert sich an dem Entwurfsmodell von Box-Jenkins

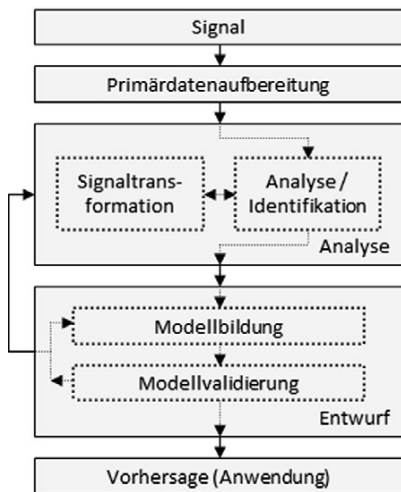


Abb. 2: Box-Jenkins-Verfahren [16].

(s. Abb. 2) [16]. Dabei werden in einer Analysephase zunächst die charakteristischen Eigenschaften der zugrundeliegenden Zeitreihen und der Einfluss exogener Größen identifiziert. In der anschließenden Entwurfsphase wird ein Modell entwickelt, das die mathematischen Zusammenhänge zwischen den Ein- und Ausgangsgrößen bei der Entstehung von Netzverlusten unter der Berücksichtigung aller relevanten und verfügbaren Einflussgrößen abbildet. Der Modellentwurf basiert auf den in der Analysephase gewonnenen Erkenntnissen. Entsprechend der Analyseergebnisse wird ein Modellansatz ausgewählt, welcher der Komplexität der ermittelten funktionalen Zusammenhänge entspricht. Das Vorgehen ist so strukturiert, dass mehrere Modellansätze in unterschiedlicher Komplexität getestet und miteinander verglichen werden. Dazu werden die Modellparameter des jeweiligen Modellansatzes geschätzt und anschließend im Rahmen simulativer Untersuchungen evaluiert, wobei die Prognosequalität anhand von Fehlermaßen beurteilt wird.

4.1 Datengrundlage

Die Datengrundlage, die bei den Untersuchungen verwendet wurde, umfasste plausible und vollständige Zeitreihen für das Jahr 2017 mit einer Abtastzeit von 15 Minuten. Dabei waren folgende Zeitreihen für das gesamte Höchstspannungsnetz der 50Hertz Regelzone verfügbar:

- Istwerte der Netzverluste (Zählwerte aus Bilanzrechnung),
- Prognose der Regelzonenlast/ Gesamtlast,
- Istwerte der Transite (Aggregation aller Lastflüsse an den Kuppelleitungen),

- Istwerte der Netzeinspeisung (Summe aller direkten Einspeisungen) und
- Prognose der Erzeugung (aggregierte Fahrplandaten der direktangeschlossenen Anlagen).

Potenzielle Einflussgrößen standen von verschiedenen lokalen Aggregationsebenen für bis zu 75 Umspannwerke und neun Regionen innerhalb der 50Hertz Regelzone zur Verfügung. Diese umfassten:

- (Day-Ahead) Prognose und Hochrechnung der Wind-einspeisung,
- (Day-Ahead) Prognose und Hochrechnung der Photovoltaikeinspeisung,
- Istwerte der vertikalen Netzlast und
- Prognose der Temperatur.

Weitere bereitgestellte potentielle Einflussgrößen waren:

- Istwerte der Kraftwerkseinspeisung (aggregierte Fahrplandaten der elektrischen Einspeisung je Kraftwerk) und
- Istwerte der Leitungsbelastung (je Leitung).

4.2 Analyse der Netzverluste und des Einflusses exogener Größen

Um das Entstehen von Netzverlusten (vgl. Kapitel 2) im 50Hertz Höchstspannungsnetz besser zu verstehen, ist die Zielstellung der Zeitreihenanalyse die Identifikation der charakteristischen Eigenschaften der Netzverluste sowie die Identifikation und Bewertung des Einflusses exogener Größen. Zur Erfüllung dieser Zielstellung wurden im Rahmen der Untersuchungen umfangreiche Zeitreihenanalysen durchgeführt, die im vorliegenden Beitrag auszugsweise vorgestellt werden. Bei der Analyse sollen lokale Phänomene aufgedeckt werden, die Ursache für die spezifische Zeitreihencharakteristik der Netzverluste sind. Die Analyse orientiert sich dabei an den drei nachfolgenden, vorab getroffenen Annahmen zur Charakteristik der Netzverlustzeitreihe.

- Innere Zusammenhänge: Autoregressive Einflüsse sind von Interesse, da damit abgeleitet werden kann, ob es innere Zusammenhänge in der Netzverlustzeitreihe gibt, die das dynamische Verhalten der Netzverluste erklären. Besteht eine Korrelation zu historischen Werten? Sind typische wiederkehrende Muster in der Zeitreihe vorhanden?
- Exogene Einflussfaktoren und typische Klassenkonfigurationen: Zunächst sollen Einflussfaktoren identifiziert werden, die das Verhalten der Netzverlustzeitreihe signifikant beeinflussen, d. h. bei der Entstehung

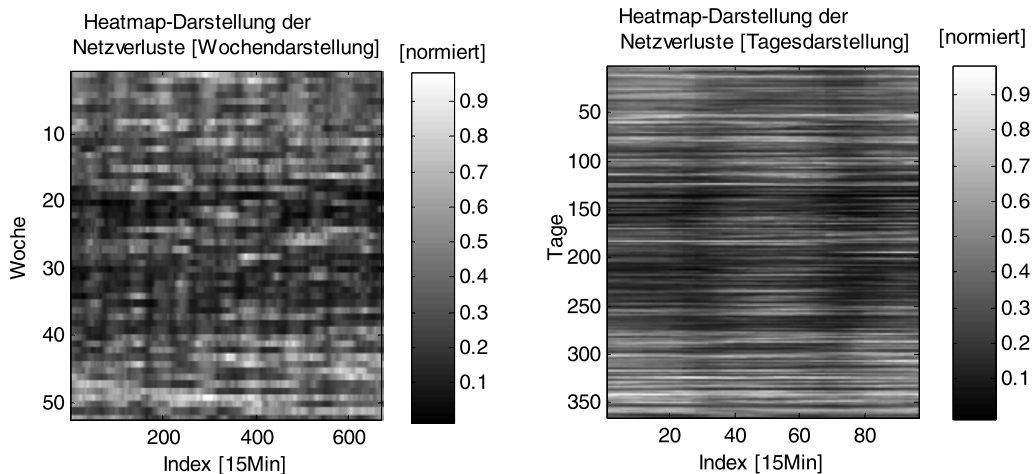


Abb. 3: Heatmap-Darstellung der Netzverluste.

von Netzverlusten verursachend sind. Weiterhin soll untersucht werden, ob bezüglich der Eigenschaften der Netzverlustzeitreihe und potentieller Einflussgrößen typische Situationen als Klassen ermittelt werden können.

- Räumlich-lokale Einflüsse: Das Höchstspannungsnetz von 50Hertz hat eine räumliche Ausdehnung. Durch die räumliche Verteilung der Einspeisung und der Verbraucher stellen sich über die Zeit verschiedene Lastflüsse auf den Leitungen des Höchstspannungsnetzes ein und verursachen Netzverluste. Es ist von Interesse, ob bezüglich der Entstehung von Netzverlusten Rückschlüsse auf räumlich-lokale Phänomene geschlossen werden können.

4.2.1 Analyse der inneren Zusammenhänge

Für die Gewinnung eines ersten Eindrucks, der Erkennung augenscheinlicher Auffälligkeiten und Indizien für saisonale Effekte ist eine Visualisierung der Zeitreihen sinnvoll. Die Abbildung 3 zeigt die normierte Zeitreihe der Netzverluste für das Jahr 2017.

In der Wochendarstellung sind die einzelnen Wochen und in der Tagesdarstellung die einzelnen Tage dargestellt. Dabei ist ein Tagesrhythmus auszumachen, bei dem die an- und absteigenden Flanken der Tagesmuster saisonal zu variierenden Zeitpunkten auftreten. Saisonale Einflüsse sind auch durch die sich jahreszeitlich unterscheidenden Werteniveaus zu erkennen. Ein Wochenrhythmus ist nicht zu erkennen. Die Abbildung 4 zeigt den Verlauf der Autokorrelationsfunktion (AKF) mit einer Verschiebung um bis zu 700 Tastpunkten.




Abb. 4: Autokorrelationsfunktion der Netzverluste.

Die AKF analysiert den mittleren linearen Zusammenhang zwischen beobachteten Werten einer Zeitreihe x zu den Zeitpunkten k und $k + \tau$, wobei τ die betrachtete zeitliche Verschiebung beschreibt. Es sind lokale Maxima bei Vielfachen von 96 Tastschritten zu erkennen. Durch die Abtastzeit von 15 Minuten erklären sich diese Maxima durch einen auftretenden Tagesrhythmus. Allerdings ist die Korrelation zu Vergangenheitswerten eher schwach ausgeprägt. Bei einer Verschiebung von 96 Tastschritten beträgt die Korrelation nur 0,52.

In Abbildung 5 sind die Werte der partiellen Autokorrelationsfunktion (PAKF) für die Netzverluste abgetragen. Die PAKF beschreibt den mittleren linearen Zusammenhang zwischen den Beobachtungswerten einer Zeitreihe x zu den Zeitpunkten k und $k + \tau$ unter Ausschaltung der Einflüsse der dazwischenliegenden Werte, wobei τ für die betrachtete zeitliche Verschiebung steht. Es besteht eine Korrelation zu den unmittelbaren Vergangenheitswerten mit einem Autoregressiven (AR) Anteil = $1, \dots, 5$. Bei Verschiebung $\tau = 96$ ist zudem der Tagesrhythmus schwach zu er-

Tab. 2: Qualitative Bewertung der Relevanz exogener Einflussgrößen.

Einflussgröße	Relevanz	Beschreibung
Windeinspeisung	Hoch	Starke Korrelation zu Netzverlusten, aber saisonal variierend; variierende Korrelation einzelner Regionen und UW
PV-Einspeisung	Niedrig	Geringe Korrelation zu Netzverlusten; geringe regionale Unterschiede
Vertikale Netzlast	Hoch	Umgekehrt proportionaler Zusammenhang zwischen Netzverlusten und vertikaler Netzlast, starke Korrelation zu Netzverlusten; beinhaltet EE-Einspeisung; keine Prognose verfügbar
Gesamtlast	Niedrig	Geringe Korrelation zu Netzverlusten
Transite	Hoch	Starke Korrelation zu Netzverlusten; keine Prognose der Transite verfügbar
Temperatur	Mittel	Mittlere Korrelation zu Netzverlusten; geringe regionale Unterschiede
KW-Einspeisung	Niedrig	Mittlere bis geringe Korrelation zu Netzverlusten; große Unterschiede einzelner Kraftwerke
Netzeinspeisung	Hoch	Starke Korrelation zu Netzverlusten; keine Prognose für Netzeinspeisung verfügbar
Erzeugung	Hoch	Starke Korrelation zu Netzverlusten




Abb. 5: Partielle Autokorrelationsfunktion der Netzverluste.

kennen. Die Analyse der inneren Zusammenhänge macht deutlich, dass der stochastische Anteil der Zeitreihe sehr ausgeprägt ist.

4.2.2 Exogene Einflussfaktoren und typische Klassenkonfigurationen

Für die Bewertung des Einflusses exogener Größen werden u. a. Korrelationsanalysen durchgeführt. Dabei wird der mittlere lineare Zusammenhang zwischen beobachteten Werten zweier Variablen bewertet. Die Abbildung 6 und die Tabelle 2 fassen die Ergebnisse der Analysen bezüglich der exogenen Größen zusammen.

Untersucht wurden der Zusammenhang zwischen den Netzverlusten und potentiellen exogenen Einflussgrößen. Die exogenen Größen mit der höchsten Relevanz sind die Windeinspeisung, die vertikale Netzlast, die Transite und die Netzeinspeisung. Aufgrund der geografischen Unterschiede bei Verortung von Windkraftanlagen und Regionen mit großem Verbrauch lassen sich bei starker Windeinspeisung hohe Lastflüsse im Höchstspannungsnetz er-

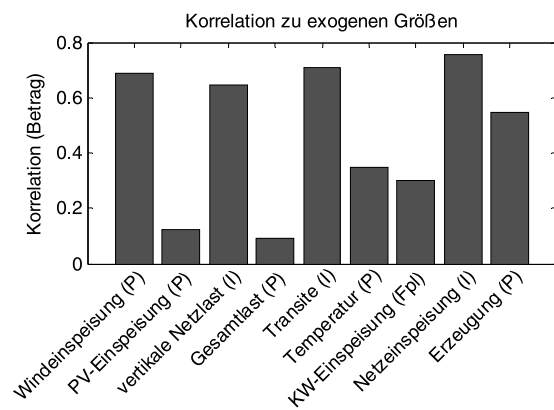


Abb. 6: Korrelation der Netzverluste zu exogenen Größen (I – Istwerte, P – Prognosewerte).

klären. Der Transport hoher elektrischer Leistungen aus Windkraft hat demnach einen großen Einfluss auf die Lastflüsse und ist somit eine wesentliche Ursache für Netzverluste im Höchstspannungsnetz [4]. Die Größen vertikale Netzlast, Transite und Netzeinspeisung lassen sich nicht unabhängig von der Windeinspeisung in der 50Hertz-Regelzone und den benachbarten Regelzonen betrachten. So ist die Windeinspeisung Bestandteil der vertikalen Netzlast sowie der Netzeinspeisung. Auch bei der Entstehung von Transit ist die Windeinspeisung ein entscheidender Faktor.

4.3 Konzeption der Prognosemethode

Laut dem Entwurfsmodell von Box-Jenkins (vgl. Abb. 2) soll anhand der aus der Zeitreihenanalyse gewonnenen Erkenntnisse ein Modellansatz abgeleitet werden, der in eine für die Vorhersage der Netzverluste spezialisierte Prognosemethode umzusetzen ist. Dafür ist zunächst ein grundlegender Modellansatz auszuwählen. Die Analyse der Netz-

Uhrzeitabhängiges Mehrschrittmodell:

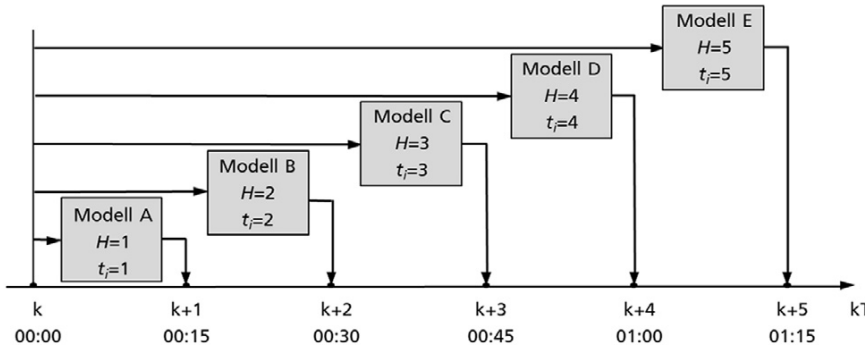


Abb. 7: Uhrzeitabhängiges Mehrschrittmodell.

verluste und deren Einflussgrößen hat gezeigt, dass innere funktionale Zusammenhänge (Tagesrhythmus), saisonale Effekte und exogene Größen die Charakteristik der Netzverlustzeitreihe prägen. Dem Modellansatz wird daher zunächst ein ARIMA (autoregressive integrated moving average) -Modellansatz zugrunde gelegt. Die grundsätzliche Beschreibung der AR- und MA-Modell wurde in Abschnitt 3.1 erläutert. Das in Gleichung (3) beschriebene ARIMA(p, q, d)-Modell (mit $\varepsilon[k]$ – Zeitreihe weißen Rauschens, a_i, b_i – Modellparameter und ∇^d – Differenzenfilter d -ter Ordnung) bietet einen etablierten Modellansatz für die Zeitreihenprognose bei instationären stochastischen Prozessen [13].

$$\nabla^d x[k] = \sum_{i=1}^p [a_i \cdot \nabla^d x[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \varepsilon[k-i] \quad (3)$$

mit: $\varepsilon[k]$ – Zeitreihe weißen Rauschens zum Zeitindex k ,
 $x[k]$ – zeitdiskrete Zeitreihe zum Zeitindex k ,
 ∇^d – Differenzenfilter d -ter Ordnung,
 p, q, d – Ordnung des ARIMA-Modells und
 a_i, b_i – Modellparameter.

Der instationäre Teil (Trend) wird durch Differenzbildung der benachbarten Zeitreihenwerte miterfasst. Differenzenfilter dienen dabei der Überführung von Zeitreihen mit stationären Eigenschaften (Linearisierung). Zur Überführung von Zeitreihen mit wiederkehrenden Mustern in Zeitreihen mit quasistationären Eigenschaften werden Differenzenfilter mit einem entsprechenden Backshift-Operator τ kombiniert, um somit historische Werten $x[k-\tau]$ bei der Modellierung zu berücksichtigen [17]. Im Fall der Netzverluste $x_{NV}[k]$ liegt ein Tagesrhythmus vor, der mit Hilfe eines festen Regelwerks für τ in die Modellgleichung eingeht. Die saisonalen Effekte werden dabei indirekt mit beachtet, da der in die Modellgleichung eingeführte historische Wert $x_{NV}[k-\tau]$ im gleichen saisonalen Bericht wie der vorherzusagende Wert liegt. Des Weiteren wird die Modellgleichung um eine exogene Komponente

$u_i[k]$ erweitert. Mit dieser können m exogene Größen, die ursächlich bei der Entstehung von Netzverlusten sind, in das Modell einbezogen werden. Die erweiterte Modellgleichung mit den Modellparametern a_i, b_i und c_i ist in Gleichung (4) aufgeführt.

$$x_{NV}[k] = \sum_{i=1}^p [a_i \cdot \nabla^d x_{NV}[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \varepsilon[k-i] + \sum_{i=1}^m c_i u_i[k] + a_0 x_{NV}[k-\tau] \quad (4)$$

mit: $\varepsilon[k]$ – Zeitreihe weißen Rauschens zum Zeitindex k ,
 $x_{NV}[k]$ – Zeitreihe der Netzverluste zum Zeitindex k ,
 $u[k]$ – Zeitreihe einer exogenen Größe zum Zeitindex k ,
 ∇^d – Differenzenfilter d -ter Ordnung mit dem Backshift-Operator τ ,
 p, q, d – Ordnung des Modells,
 m – Anzahl der exogenen Größen und
 a_i, b_i, c_i – Modellparameter.

Für die Prognose der Netzverluste werden Vorhersagewerte für mehrere Zeitschritte in die Zukunft benötigt, die als Vorhersagehorizonte $H = 1, 2, \dots$ bezeichnet werden. In [17] wird für den Einsatz von Prognosemodellen für mehrere Vorhersagehorizonte das Konzept der Mehrschrittmodellierung favorisiert. Dabei wird für jeden Vorhersagehorizont H ein separates Modell eingesetzt. In [18] wird dieses Konzept als uhrzeitabhängige Mehrschrittmodellierung erweitert, sodass zusätzlich separate Modelle für die Beschreibung der Zeitreihe in Abhängigkeit der Uhrzeit (Uhrzeitindex t_i) eingesetzt werden. Ein Modell beschreibt dabei die Zeitreihe für eine Uhrzeit. Jeder Uhrzeitindex t_i kann genau einer Uhrzeit zugeordnet werden. Bei Zeitreihen, die wie die Netzverluste Tagesmuster aufweisen, bietet die uhrzeitabhängige Mehrschrittmodellierung hinsichtlich der Prognosegenauigkeit Vorteile gegenüber einfachen Mehrschrittmodellen [18]. Abbildung 7 zeigt das uhrzeitabhängige Mehrschrittmodell.

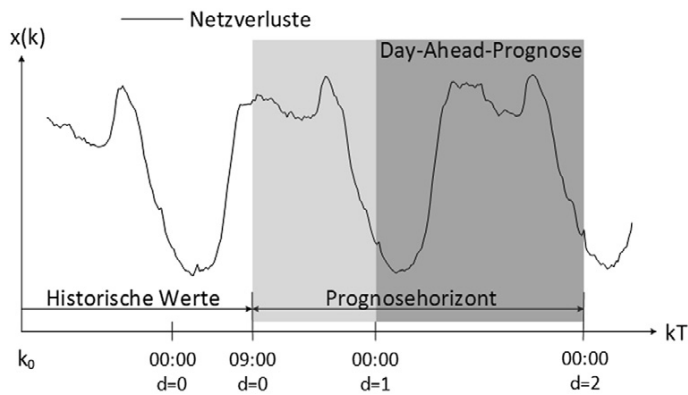


Abb. 8: Prognosehorizont bei der Prognose der Netzverluste.

Um auch nichtlineare Zusammenhänge berücksichtigen zu können, wird die Modellierung auf KNN als zugrundeliegendem Modellansatz aufgebaut. Die grundsätzliche Funktionsweise von KNN wurde in Abschnitt 3.2 aufgeführt. Der zur Prognose der Netzverluste spezialisierte Modellansatz, basierend auf KNN, ist Gegenstand des vorliegenden Beitrages. Für die Modellierung wurde ein KNN in der Form eines Feed-Forward-Netztes eingesetzt. Die Informationsverarbeitung erfolgt dabei ausschließlich vorwärtsgerichtet. Der Entwurf und die Simulation des KNN wurde in der Programmiersprache Python mit der Open Source Deep-Learning-Bibliothek Keras durchgeführt. Die bisherigen Schlussfolgerungen zur Herleitung der Gleichung (4) werden für die Eingangsbelegung des KNN herangezogen, sodass die in Gleichung (4) enthaltenen Größen auch die Eingangsbelegung des KNN-Modells zur Prognose der Netzverluste darstellen. Für die simulativen Untersuchungen wurde das Konzept der uhrzeitabhängigen Mehrschrittmodellierung angewendet.

5 Simulative Untersuchungen und Evaluierung

5.1 Untersuchungsszenarien

Das in Abschnitt 4 konzipierte Prognosemodell wurde in umfangreichen simulativen Untersuchungen angewendet, um verschiedene Untersuchungsszenarien bezüglich der Prognosequalität miteinander zu vergleichen. Variierende Konfigurationen von Hyperparametern des KNN-Modells und Konstellationen bei der Berücksichtigung exogener Größen wurden untereinander und dem ARIMA-basierten Modell (s. Gleichung (4)) gegenübergestellt. Die Berücksichtigung exogener Größen beschränkt sich auf

die als Prognose für die Regelzone zur Verfügung stehenden Größen Windeinspeisung, PV-Einspeisung, Temperatur, Gesamlast und Erzeugung, die bei allen aufgeführten Untersuchungsszenarien als Eingangsgröße dienen. Alle exogenen Größen werden jeweils als Differenzenmodell aufgeschaltet, sodass je exogener Größe $u_i[k + H]$ und $u_i[k + H - \tau]$ in das jeweilige Modell eingehen. Das eingesetzte KNN-Modell wurde mit drei Schichten, linearen Aktivierungsfunktionen in der Ein- und Ausgabeschicht, einem stochastischen Gradientenabstiegsverfahren als Trainingsfunktion mit einem Abbruchkriterium nach 3000 Trainingsiterationen und der Minimierung des quadratischen Fehlers als Zielfunktion konzipiert und in den Untersuchungen angewendet. Im Rahmen der umfangreichen Untersuchungen, deren Ergebnisse in diesem Beitrag nur auszugsweise aufgeführt werden, wurde eine Sensitivitätsanalyse hinsichtlich Trainingsfunktion, Zielfunktion, Trainingsiterationen, Anzahl der Schichten, Anzahl der Knoten und der Eingangsbelegung durchgeführt. Das KNN-Modell hat sich dabei mit der vorab beschriebenen Konfiguration als vorteilhaft erwiesen.

Der vorliegende Datenbestand wurde dazu in Trainings- und Validierungsdaten aufgeteilt. Der Trainingszeitbereich umfasst den 01.01.2017 bis 31.08.2017 und der Validierungszeitbereich den 01.09.2017 bis 31.12.2017. Mit den Trainingsdaten wurden die Modellparameter des ARIMA-basierten Modells ermittelt und das Training des KNN durchgeführt. Mit den Validierungsdaten wurden die Modelle angewendet und evaluiert. Alle Daten wurden für die Untersuchungen normiert. Für alle Untersuchungsszenarien wurde der Day-Ahead-Beschaffungsprozess der Netzverluste simuliert. Dafür wurde eine rollierende Prognose erstellt, die täglich 09:00 Uhr für den Folgetag von 00:15 Uhr bis 24:00 Uhr Prognosewerte liefert. Bei Zeitreihen mit einer Abtastzeit von 15 Minuten entspricht das einer Prognose für die Vorhersagehorizonte $H = 60, \dots, 156$ (s. Abb. 8).

Tab. 3: Untersuchungsszenarien und Fehlermaße.

Nr.	Modell-ansatz	Uhrzeitabh. Mehrschrittmodell	Weitere exog. Größen	KNN Konfiguration Aktivierungsfunktion und Anzahl Knoten in Hidden-Schicht	ME	STD	MAE	MSE
1	ARIMA				0,014	0,116	0,089	0,014
2	ARIMA	x			0,015	0,114	0,087	0,013
3	KNN			linear 30 Knoten	0,014	0,117	0,091	0,014
4	KNN	x		linear 30 Knoten	0,014	0,115	0,088	0,013
5	KNN	x		Tangens Hyperbolicus 30 Knoten	0,018	0,117	0,090	0,014
6	KNN	x	Windeinsp. je UW	linear 50 Knoten	0,012	0,106	0,084	0,011

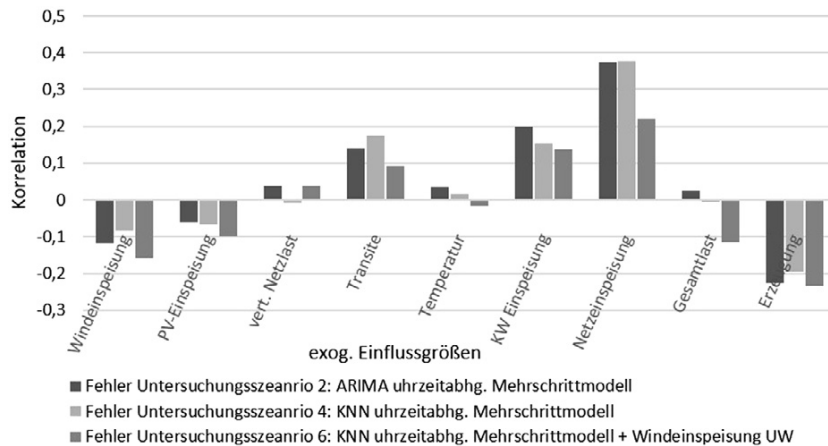


Abb. 9: Korrelation zwischen Prognosefehler und den exogenen Größen.

5.2 Evaluierung

Die Ergebnisse der simulativen Untersuchungen sind in Tabelle 3 dargestellt. Die Ergebnisse stellen lediglich einen Auszug der durchgeführten Untersuchungen dar und fassen die wesentlichen Erkenntnisse zusammen. Für die Bewertung der Prognosequalität wurden verschiedene Fehlermaße des Prognosefehlers E berechnet. Die dargestellten Fehlermaße sind der Mittelwert (mittlerer Fehler – ME), die Standardabweichung (STD), der Mittelwert des Betrages (mittlerer absoluter Fehler – MAE) und der Mittelwert des Quadrates (mittlerer quadratischer Fehler – MSE) des Prognosefehlers. Die ausgewiesenen Fehlermaße wurden auf Basis der normierten Daten berechnet.

Die Ergebnisse zeigen, dass die uhrzeitabhängige Mehrschrittmodellierung geringere Fehler gegenüber der Mehrschrittmodellierung ausweist und die Netzverluste aufgrund der enthaltenen Tagesmuster jeweils durch das KNN als auch durch das ARIMA-basierte Modell exakter abbildbar sind. Die uhrzeitabhängige Mehrschrittmodellierung erweist sich demnach bei der Netzverlustprognose bezüglich der Prognosegenauigkeit vorteilhaft. Die Anwendung des KNN-Modells kann im Vergleich zum ARIMA-basierten Modellansatz bei gleicher Eingangsbelegung keine Ver-

besserung der Prognosequalität erzielen. Die Verwendung einer nichtlinearen Aktivierungsfunktion (z. B. Tangens Hyperbolicus) bringt zudem ebenfalls keine Verbesserung. Es ist zu vermuten, dass durch die stückweise Modellierung mittels uhrzeitabhängiger Mehrschrittmodellierung die nichtlinearen Effekte bereits sehr gut erfasst werden und die Vorteile von KNN bei nichtlinearen Problemstellungen hier nicht zum Tragen kommen. Die Berücksichtigung der Prognosen der Windeinspeisung aller Umspannwerke (UW) bewirkt jedoch eine signifikante Verbesserung der Prognosequalität. Eine Erhöhung der Knotenanzahl auf 50 wirkte sich dabei vorteilhaft aus.

Die verwendeten exogenen Größen müssen beim operativen Einsatz der Netzverlustprognose ebenfalls als Prognose vorliegen. Die gezeigten Untersuchungen konzentrieren sich daher auf den realen Anwendungsfall des operativen Einsatzes der Netzverlustprognose für die Day-Ahead Beschaffung. Die vorhandene Datengrundlage umfasst jedoch noch weitere exogene Größen, die bisher nicht als Prognosen verfügbar sind. Die Abb. 9 zeigt die Korrelation der Prognosefehler der Untersuchungszenarien 2, 4 und 6 mit den Istwerten aller exogenen Größen bezüglich der gesamten Regelzone. Wenn ein Modell alle systematischen Einflussfaktoren exakt einberechnet, dann umfas-

sen die Modellfehler nur noch zufällig auftretende Abweichungen zwischen den Istwerten und den Modellausgängen in Form von weißem Rauschen [13, 17]. Nach dieser Erkenntnis korrelieren nicht berücksichtigte signifikante Einflussgrößen mit den Modellfehlern, da in den Situationen, in denen die ursächliche Größe einen kausalen Einfluss ausübt, der Modellfehler zwangsläufig ansteigt. Die wesentliche Einflussgröße, die bei der Modellierung aufgrund der bisher nicht zur Verfügung stehenden Prognose nicht mit einberechnet wurde, ist die Netzeinspeisung. In Abb. 9 wird deutlich, dass die Korrelation der Netzeinspeisung mit den Prognosefehlern am stärksten ist. Beim Untersuchungsszenario 6 ist die Korrelation zur Netzeinspeisung allerdings deutlich geringer. Es ist zu vermuten, dass durch die Berücksichtigung der Windeinspeisungsprognosen je Umspannwerk die Effekte, die die Netzeinspeisung auf die Entstehung der Netzverluste ausübt, anteilig verwertet werden können. Gleiches gilt für die Transite. Das auch leichte Korrelationen der Prognosefehler zu aufgeschalteten Größen vorhanden sind, kann damit erklärt werden, dass die Korrelation zu den Istwerten der exogenen Größen aufgeführt ist. Diese können noch Informationen enthalten, die durch die Abweichung von Prognose und Istwerten nicht in das Prognosemodell der Netzverlustprognose eingehen. Es kann festgehalten werden, dass wesentliche Einflussgrößen bei der Netzverlustprognose unberücksichtigt bleiben. Diese bieten sinnvolle Anknüpfungspunkte für weiterführende Forschungsarbeiten.

6 Zusammenfassung und Ausblick

Die Netzbetreiber benötigen für den bedarfsgerechten und günstigen Einkauf von Verlustenergie möglichst exakte Prognosen. Die bei der Energieübertragung entstehenden Netzverluste in Leitungen und Betriebsmitteln sind von zahlreichen Faktoren abhängig. Einen besonderen Einfluss hat dabei die fluktuierende und größtenteils verbrauchsferne Energieerzeugung aus erneuerbaren Energien, insbesondere der Windenergie. Aufgrund der dezentralen Erzeugung muss die Energie über größere Strecken zu den Verbrauchszentren transportiert werden, wodurch es zu einer stärkeren Belastung der Übertragungsleitungen kommt und höhere Verluste entstehen. Gleichzeitig steigt durch die Digitalisierung der Energiewirtschaft die Anzahl der messtechnisch erfassten Daten und exogenen Einflussgrößen signifikant an. Maschinelle Lernverfahren mit KNN zeichnen sich dadurch aus, dass diese aus umfangreichen nichtlinearen Daten die inneren Zusammen-

hänge und Abhängigkeiten identifizieren. Durch das Erlernen des Ein- und Ausgangsverhaltens eines unvollständig beschreibbaren Systems ist es KNN möglich, die mathematischen Zusammenhänge in einem Modell abzubilden.

Für die Netzverlustprognose im Übertragungsnetz der 50Hertz Regelzone wurde im Ergebnis ein leistungsstarkes, auf die Problemstellung der Netzverluste spezialisiertes, KNN-Modell entwickelt. In den aufgeführten Untersuchungen konnte gezeigt werden, dass die neuartige Prognosemethode, basierend auf nichtlinearen stochastischen Zeitreihenmodellen, zu einer Verbesserung der Prognosequalität führt.

Das in der vorliegenden Arbeit entwickelte Prognosemodell steigert die Prognosegüte im Vergleich zum bisherigen Modell um sieben Prozent und dient als Grundlage für die Day-Ahead-Beschaffung von Energie zum Ausgleich der Netzverluste [5]. Das Prognosemodell ist seit Juni 2019 bei 50Hertz operativ im Einsatz.

Anknüpfungspunkte an die vorliegende Forschungsarbeit bestehen vorrangig in der Untersuchung erweiterter Modellansätze mit tiefen Künstlichen Neuronalen Netzen und komplexeren Netzarchitekturen, um die Ergebnisse weiter zu verbessern. Insbesondere Deep Learning Ansätze und die hierfür zur Verfügung stehenden Werkzeuge bieten umfangreiche Möglichkeiten zur Beantwortung weiterführender Forschungsfragen zum Thema Netzverlustprognose, insbesondere vor dem Hintergrund der ansteigenden Datenverfügbarkeit.

Trotz neuer Methoden und Werkzeuge zur Zeitreihenprognose sind effektive Datenanalyseverfahren im Hinblick auf die Entwicklung von leistungsfähigen Prognosemodellen unverzichtbar. Speziell im Hinblick auf die Digitalisierung sind Verfahren notwendig, die den Informationsgehalt aus einer stetig wachsenden Datenmenge extrahieren können. Damit münden Verfahren zur Datenkomprimierung, Dimensionsreduktion und das zusätzliche Einbringen von Expertenwissen in weiterem Forschungsbedarf.

Andere, äußerst interessante Fragestellungen resultieren wiederum grundsätzlich aus dem Einsatz des maschinellen Lernens. Maschinelle Lernverfahren liefern oftmals hervorragende Ergebnisse, haben jedoch den Nachteil, dass Menschen die Ergebnisse aufgrund des Black-Box-Ansatzes nicht mehr nachvollziehen können. Daher ist es notwendig, Verfahren für die Erklärbarkeit zu entwickeln, sodass Benutzer diese verstehen können, um einerseits das Vertrauen in die Verfahren zu vertiefen und andererseits Fälle analysieren und behandeln zu können, in denen die Verfahren weniger gute Ergebnisse liefern.

Literatur

1. Bundesgesetzblatt, *Gesetz über die Elektrizitäts- und Gasversorgung (Energiewirtschaftsgesetz – EnWG)*, Bundesgesetzblatt, Berlin: 2005.
2. Bundesgesetzblatt, *Verordnung über den Zugang zu Elektrizitätsversorgungsnetzen (Stromnetzzugangsverordnung – StromNZV)*, Bundesgesetzblatt, Berlin: 2017.
3. Bundesnetzagentur, *Beschluss zur Festlegung des Ausschreibungsverfahrens für Verlustenergie und des Verfahrens zur Bestimmung der Netzverluste (BK6-08-006)*, Bundesnetzagentur, Bonn: 21.10.2008.
4. S. Bothor, *Prognose von Netzverlusten*, Dissertation, Institut für Energiewirtschaft und Rationelle Energieanwendung, Universität Stuttgart, 2019.
5. Pressemitteilung, *50Hertz reduziert Kosten durch den Einsatz Künstlicher Intelligenz*, Berlin, 09.12.2019. [Online]. Verfügbar unter: <https://www.50hertz.com/de/News/Details/id/6172/50hertz-reduziert-kosten-durch-einsatz-kuenstlicher-intelligenz>. [Zugriff am 24.04.2020].
6. VDEW e. V., *Netzverluste – Eine Richtlinie für ihre Bewertung und ihre Vermeidung*, VDEW Energieverlag, Frankfurt (Main): 1978.
7. D. Oeding, B. R. Oswald, *Elektrische Kraftwerke und Netze*, 7. Auflage, Springer, Heidelberg: 2011.
8. K. Mehlhorn, J. Kliemt, *EW Fachthema – Bestimmung der elektrischen Verluste im Netz eines städtischen Netzbetreibers*, 2004.
9. L. Fickert, W. Spitzl, E. Schmutzger, W. Brandauer, *Strategien zur Minimierung von Netzverlusten*, 6. Internationale Energiewirtschaftstagung an der TU Wien, Wien: 2009.
10. Das 50Hertz-Netz in Zahlen – Strukturmerkmale (Stand 12/2018). [Online]. Verfügbar unter: <https://www.50hertz.com/>. [Zugriff am 24.04.2020].
11. J. Wernstedt, *Experimentelle Prozessanalyse*, VEB Verlag Technik, Berlin: 1989.
12. P. J. Brockwell, R. A. Davis, *Introduction to Time Series and Forecasting*, Springer-Verlag, New York: 1996.
13. R. Schlittgen, B. Streitberg, *Zeitreihenanalyse*, 9. Auflage Oldenburg Wissenschaftsverlag, München Wien: 2001.
14. S. Raschka, *Machine Learning mit Python*, Mitp Verlag, Frechen: 2017.
15. G. Rey, K. Wendler, *Neuronale Netze – Eine Einführung in die Grundlagen, Anwendungen und Datenauswertungen*, 3. Auflage, Hogrefe Verlag, Bern: 2018.
16. G. E. P. Box, G. M. Jenkins, G. C. Reinsel, *Time Series Analysis – Forecasting and Control*, 3. Auflage, Englewood Cliffs, Prentice Hall: 1994.
17. P. Bretschneider, *Ein Beitrag zur Vorhersage musterbasierter nichtlinearer stochastischer Signale*, Dissertation, Verlag ISLE, Ilmenau: 2002.
18. S. Klaiber, S. Waczowicz, I. Konotop, D. Westermann, R. Mikut, P. Bretschneider, *Prognose für preisbeeinflusstes Verbraucherverhalten*, in *at – Automatisierungstechnik*, Bd. 65, Nr. 3, Seiten 179–188, 2017.

Autoreninformationen



Dipl.-Ing. Stefan Klaiber

Fraunhofer IOSB, IOSB-AST Ilmenau, Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung, Am Vogelherd 90, 98693 Ilmenau, Germany
stefan.klaiber@iosb-ast.fraunhofer.de


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



M. Sc. Fabian Bauer

Technische Universität Ilmenau, Fakultät für Elektrotechnik und Informationstechnik, Fachgebiet Energieeinsatzoptimierung, Gustav-Kirchhoff-Str. 5, 98693 Ilmenau, Germany
fabian.bauer@tu-ilmenau.de

M. Sc. Fabian Bauer ist wissenschaftlicher Mitarbeiter an der Fakultät für Elektrotechnik und Informationstechnik im Fachgebiet Elektrische Energieeinsatzoptimierung an der TU Ilmenau. Forschungsschwerpunkte: Zeitreihenprognosen, Maschinelle Lernverfahren, Datenanalysemethoden.



Univ.-Prof. Dr.-Ing. Peter Bretschneider

Technische Universität Ilmenau, Fakultät für Elektrotechnik und Informationstechnik, Fachgebiet Energieeinsatzoptimierung, Gustav-Kirchhoff-Str. 5, 98693 Ilmenau, Germany
peter.bretschneider@tu-ilmenau.de

Univ.-Prof. Dr.-Ing. Peter Bretschneider ist Professor an der Fakultät für Elektrotechnik und Informationstechnik für das Fachgebiet Energieeinsatzoptimierung an der TU Ilmenau und Leiter der Abteilung Energie des Fraunhofer IOSB-AST. Forschungsschwerpunkte: Energiemanagement, Zeitreihenanalyse und Prognose, Optimierung und Betriebsführung in Stromversorgungsnetzen, Smart Grids und Energiemärkte.