

Day-Ahead Netzzustandsprognose auf Mittelspannungsebene mit neuronalen Netzen

Sebastian Storch (*)¹, Michael Finkel¹, Martin Uhrig², Michael Kreißl³,
Lothar Behringer⁴

¹ TH Augsburg, An der Hochschule 1, 86161 Augsburg (DE), +49 821 5586 3095, sebastian.storch@hs-augsburg.de, www.tha.de

² LEW Verteilnetz GmbH, Schaetzlerstraße 3, 86150 Augsburg (DE), www.lew-verteilnetz.de

³ SWM Infrastruktur GmbH & Co. KG, Emmy-Neother-Straße 2, 80992 München (DE), www.swm.de

⁴ Stadtwerke Neuburg a. d. Donau, Heinrichsheimstraße 2, 86633 Neuburg a. d. Donau (DE), www.stadtwerke-neuburg.de

Kurzfassung: Bei der Umsetzung von Energie-, Verkehrs- und Wärmewende ist eine Offenlegung und Nutzung von Flexibilitäten im Verteilnetz notwendig. Für eine effektive Steuerung dieser Flexibilitäten ist die Erfassung des Netzzustands für die kommenden 24 h von großem Nutzen. In dieser Arbeit wird eine solche Day-Ahead Netzzustandsprognose für die Mittelspannungsebene thematisiert. Das Prognosemodell besteht aus einem neuronalen Netz, welches ausgehend von einer Lastprognose über 24 h den Netzzustand ermittelt. Die Lastprognose wird mit einem neuronalen Netz bestehend aus Long Short-Term Memory (LSTM) Schichten umgesetzt, das anschließende Modell ist ein neuronales Feed-Forward Netz. Durch die Verkettung der beiden Modelle werden Leitungsauslastungen und Knotenspannungen in einem Mittelspannungsnetzabschnitt eines kleinstädtischen Verteilnetzbetreibers prognostiziert. Die Abweichungen der Prognosen vom tatsächlichen Wert sind geringfügig und liegen innerhalb eines anerkannten Toleranzbereichs für Live-Zustandsschätzungen. Mittels eines Generative Adversarial Networks (GAN) zur Erweiterung von Extremszenarien und einer Kern-Dichte-Schätzung von Prognoseabweichungen wird eine strukturelle Unterschätzung von lokalen Extrema verhindert. Eine Sensitivitätsanalyse im Hinblick auf die Trainingsdaten der Modelle quantifiziert den Nutzen eines Messgeräts an einer Netzstation. Zudem impliziert die Analyse Kriterien, die das optimale Platzieren von Messgeräten in einem Netzabschnitt ermöglichen.

Keywords: Netzzustandsschätzung, Mittelspannung, Sensitivitätsanalyse, Künstliche Intelligenz, Neuronale Netze, Deep Learning, Long Short-Term Memory, LSTM, Generative Adversarial Network, GAN

1 Motivation

Die Transformation der Energie-, Verkehrs- und Wärmesektoren im Zuge der Energiewende stellt eine zentrale Herausforderung unserer Zeit dar. Das Bestreben, fossile Brennstoffe durch nachhaltige Alternativen zu ersetzen, hat zahlreiche Auswirkungen auf die elektrischen Energieversorgungsnetze. Mit dem zunehmenden Einsatz dezentraler Erzeugungsanlagen und einer steigenden Zahl elektrischer Verbraucher wie Wärmepumpen und E-Fahrzeuge erfahren Übertragungs- und Verteilnetze signifikante Veränderungen in ihren Einspeisungen und Bezügen [1]. Gleichzeitig sind Verteilnetzbetreiber mit historisch bedingten Schwächen in der Überwachung und Steuerung der Mittel- und Niederspannungsnetze konfrontiert. Diese Netze, die ursprünglich für eine zentralisierte Energieversorgung konzipiert wurden, müssen nun beispielsweise eine dezentralisierte, fluktuierende Energieeinspeisung aus erneuerbaren Quellen bewältigen. Hierdurch steigt der Bedarf an präziser und vorausschauender Überwachung und Steuerung des Verteilnetzes signifikant.

Die fortschreitende Digitalisierung und der Einsatz von künstlicher Intelligenz (KI) bieten hier neue Möglichkeiten [2]. KI-Systeme können komplexe Datenmuster erkennen und Prognosen erstellen, die weit über die Fähigkeiten traditioneller Methoden hinausgehen. Dies eröffnet ein enormes Potential für die Optimierung der Netzbetriebsführung. Eine konkrete Anwendung ist beispielsweise eine Day-Ahead Zustandsprognose des Mittelspannungsnetzes mit Hilfe von Neuronalen Netzen, die in dieser Arbeit thematisiert wird. Diese Prognosen liefern Auskunft über Flexibilität im Netz. Sie ermöglichen die Koordinierung aller Maßnahmen mit Vorlauf – beispielsweise Redispatch, Schaltmaßnahmen bei Wartungsarbeiten und andere notwendige Anpassungen. Durch solch eine vorausschauende Planung können Risiken minimiert und die Effizienz des Netzbetriebs gesteigert werden.

Eine detaillierte Untersuchung der Qualität einer KI-basierten Netzzustandsprognose für den Folgetag ist somit für Verteilnetzbetreiber von hoher Relevanz.

Ein Netzzustandsprognosemodell liefert zusätzliche Asset-strategische Schlüsse. Eine Sensitivitätsanalyse des Modells im Hinblick auf die zugrundeliegende Datenbasis zeigt, welchen Einfluss ein Messgerät an einer Netzstation hat. Hierdurch kann der Einbau von Messgeräten koordiniert werden, sodass die Prognose einerseits die gewünschte Genauigkeit erreicht, gleichzeitig aber die Kosten für Messtechnik geringgehalten werden.

Die vorliegende Arbeit leistet somit einen wesentlichen Beitrag zum Verständnis der Potenziale von KI in der Energieversorgung. Sie beleuchtet, wie durch den Einsatz moderner Technologien eine zuverlässige, effiziente und zukunftsfähige Energieversorgung sichergestellt werden kann, die den Herausforderungen der Energiewende gerecht wird.

2 Methodik

Die methodischen Schritte dieser Arbeit lassen sich grob in zwei Segmente gliedern. Zum einen wird zunächst ein Verfahren entwickelt, das eine grundlegende Netzzustandsprognose ermöglicht. Hierauf aufbauend werden dann im zweiten methodischen Abschnitt Veränderungen am Basismodell vorgenommen, um das Verhalten bei Extremwerten zu verbessern und die Sensitivität des Modells zu evaluieren. Die Methodik der Netzzustandsprognose nimmt eine zentrale Rolle in der gesamten Arbeit ein und wird daher in Abschnitt 2.1 ausführlich

erörtert. Die Techniken zur Handhabung von Extremwerten (Abschnitt 4.2) und zur Sensitivitätsanalyse (Abschnitt 4.3) sind jeweils auf ihre spezifischen Kapitel beschränkt und werden an den entsprechenden Stellen detailliert dargestellt.

2.1 Vorgehen bei der Zustandsprognose

Der Netzzustand auf Mittelspannungsebene setzt sich aus den Knotenspannungen an den Netzstationen und den Leitungsauslastungen zusammen. Diese Größen werden auf Basis der verfügbaren Daten eines Tages für den Folgetag prognostiziert. Die Vorhersage wird durch die Verknüpfung von zwei neuronalen Netzen realisiert. Schematisch ist das Vorgehen in Abbildung 1 dargestellt. Betrachtet

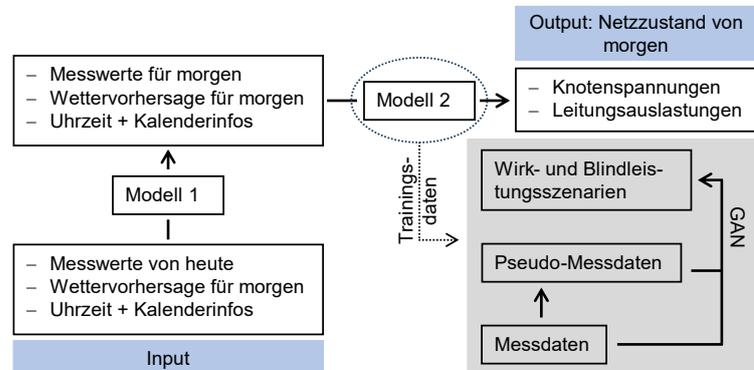


Abbildung 1: Schematisches Vorgehen bei der Netzzustandsprognose für den Folgetag.

wird ein Netzabschnitt mit den Knotenpunkten v_1, \dots, v_n und den Leitungen l_1, \dots, l_m . Es seien $k \leq n$ Knotenpunkte mit Messgeräten ausgerüstet, deren Messdaten im operativen Betrieb live ausgelesen werden können. Ohne Beschränkung der Allgemeinheit seien demnach zu einem Zeitpunkt t die Messwerte $m_{v_1}(t), \dots, m_{v_k}(t)$ an den Knotenpunkten v_1, \dots, v_k verfügbar. In dieser Arbeit bestehen die Messwerte an einer Station stets aus einem Wirk- und einem Blindleistungsmesswert, die in 15-minütiger Auflösung übermittelt werden. Zudem sei die Wettervorhersage $w(t)$ bestehend aus einer Temperatur- und einer Sonnenscheindauerprognose für den Zeitpunkt t gegeben. Zuletzt seien Kalenderinformationen (Werktag, Samstag, Feiertag) und Uhrzeit zum Zeitpunkt t durch $k(t)$ gegeben. Durch das Modell 1 werden zu einem Zeitpunkt t_0 die Messwerte für den Folgetag prognostiziert. Dabei fließen die Messwerte der letzten 24 h, die Wettervorhersage und die Kalender- und Uhrzeitinformationen ein. Es bezeichne $\hat{m}_{v_i}(t)$ die Prognose der Messwerte am Knoten v_i zum Zeitpunkt t . Dann ist Modell 1 formal definiert durch die Abbildung:

$$M_1: \begin{pmatrix} m_{v_1}(t_{-95}) & \cdots & m_{v_k}(t_{-95}) & w(t_1) & k(t_1) \\ \vdots & \ddots & \vdots & \vdots & \vdots \\ m_{v_1}(t_0) & \cdots & m_{v_k}(t_0) & w(t_{96}) & k(t_{96}) \end{pmatrix} \mapsto \begin{pmatrix} \hat{m}_{v_1}(t_1) & \cdots & \hat{m}_{v_k}(t_1) \\ \vdots & \ddots & \vdots \\ \hat{m}_{v_1}(t_{96}) & \cdots & \hat{m}_{v_k}(t_{96}) \end{pmatrix}$$

Modell 1 ist ein neuronales Netz bestehend aus zwei Long Short-Term Memory Schichten (LSTM-Schichten) und einer vollständigen Schicht [3]. Die Trainingsdaten von Modell 1 bestehen aus 60 % der verfügbaren Messdaten, den zugehörigen Wetterdaten vom Deutschen Wetterdienst (DWD), zyklisch kodierten Uhrzeiten und One-Hot-kodierten Kalenderinformationen. Jede Messreihe wird vor dem Training auf den Wertebereich $[0,1]$ skaliert. Als Verlustfunktion beim Training wird die mittlere quadratische Abweichung (Mean Squared Error: MSE) verwendet:

$$\frac{1}{k \cdot T} \sum_{i,j} (\hat{m}_{v_i}(t_j) - m_{v_i}(t_j))^2$$

Um den Netzzustand zu bestimmen, bringt Modell 2 zu einem Zeitpunkt t die Messwerte $m_{v_1}(t), \dots, m_{v_k}(t)$ in einen Zusammenhang mit den Knotenspannungen $u_{v_1}(t), \dots, u_{v_n}(t)$ und den Leitungsauslastungen $a_{l_1}(t), \dots, a_{l_m}(t)$ im Netzabschnitt. Das Modell 2 ist formal definiert durch

$$M_2: (m_{v_1}(t), \dots, m_{v_k}(t), w(t), k(t)) \mapsto (\hat{u}_{v_1}(t), \dots, \hat{u}_{v_n}(t), \hat{a}_{l_1}(t), \dots, \hat{a}_{l_m}(t))$$

wobei $\hat{u}_{v_1}(t), \dots, \hat{u}_{v_n}(t)$ und $\hat{a}_{l_1}(t), \dots, \hat{a}_{l_m}(t)$ die Schätzungen Knotenspannungen und Leitungsauslastungen bezeichnen. Die Trainingsdaten von Modell 2 werden durch Netzberechnungen in der Software PowerFactory [4] erzeugt: Durch das Anlegen von Wirk- und Blindleistungszeitreihen an allen Netzstationen im betrachteten Netzabschnitt und der Durchführung einer quasi-dynamischen Simulation, werden die Knotenspannungen und Leitungsauslastungen bestimmt. Die entstehende Ergebnisdatei liefert den Zusammenhang zwischen den Leistungswerten und dem Netzzustand. Modell 2 ist ein neuronales Netz bestehend aus drei vollständigen Schichten, ein sogenanntes neuronales Feed-Forward Netz. Als Verlustfunktion beim Training von Modell 2 wird erneut die MSE-Funktion verwendet, die in diesem Fall wie folgt definiert ist:

$$\frac{1}{T} \sum_j \left(\frac{1}{n} \sum_i (\hat{u}_{v_i}(t_j) - u_{v_i}(t_j))^2 + \frac{1}{m} \sum_i (\hat{a}_{l_i}(t_j) - a_{l_i}(t_j))^2 \right)$$

Durch die Verkettung von Modell 1 und Modell 2 werden somit zunächst die vorliegenden Live-Messungen für die nächsten 24 h prognostiziert (Modell 1). Auf Basis dieser Prognosen bestimmt Modell 2 anschließend die Knotenspannungen und Leitungsauslastungen. Die Parametrierung der beiden Modelle und die Qualität der Zustandsprognose wird in Kapitel 4.1 aufgezeigt.

2.2 Einordnung in den Stand der Technik

In der Literatur findet man eine Vielzahl von Veröffentlichungen, die sich mit den in dieser Arbeit vorgestellten Verfahren befassen. Die 24-Stunden-Prognose von Wirk- und Blindleistungszeitreihen durch Modell 1 wird üblicherweise als kurzfristige Lastprognose bezeichnet. Überblicksarbeiten wie [5] und [6] zeigen, dass der Einsatz von Deep Learning-Verfahren in den letzten Jahren aufgrund ihrer ausgezeichneten Prognosefähigkeit stark zugenommen hat. So wird in [6] betont, dass Deep Learning-Modelle flexibler und anpassungsfähiger als andere Modelltypen sind und die Genauigkeit der Lastprognose erheblich verbessern. Häufig werden in diesem Fall Deep Learning-Modelle mit LSTM-Schichten eingesetzt, deren Zellen durch Input-, Output- und Forget-Gates besonders gut für Zeitreihenprognosen geeignet sind [7]. Konkret wird ein solches Modell für Lastprognosen in [8] und [9] eingesetzt. Die positiven Ergebnisse mit einem LSTM bei Lastprognosen machen es zu einer hervorragenden Basisarchitektur für Modell 1.

Im Bezug auf die Netzzustandsbestimmung, die von Modell 2 durchgeführt wird, gibt es ebenfalls einige Ansätze in der Literatur, bei dem der Netzzustand auf Basis vorhandener Messwerte durch ein neuronales Feed-Forward Netz approximiert wird [10,11,12]. Der üblicherweise für Hoch- und Höchstspannungsnetze verwendete Weighted-Least-Squares (WLS) Algorithmus zur State Estimation [13] wird in [11] mit neuronalen Netzen verglichen. Hierbei zeigt sich, dass das Verfahren mit neuronalen Netzen auf Verteilnetzebene bessere Ergebnisse erzielt.

Obwohl zahlreiche Publikationen die Aufgabenbereiche von Modell 1 und Modell 2 behandeln, mangelt es an Literatur zu einer Day-Ahead Zustandsprognose, also einer Verknüpfung beider Verfahren. In den Arbeiten [14] und [15] wird zwar eine solche Verknüpfung thematisiert, jedoch ohne den Einsatz von Deep Learning Verfahren für die Lastprognose, stattdessen aber wird der WLS-Algorithmus zur Zustandsbestimmung verwendet.

Das im Hinblick auf die Lastspitzenbehandlung implementierte Verfahren zur Erzeugung künstlicher Extremszenarien (Abschnitt 4.2.1), findet sich ähnlich in [16]. Dort liegt der Fokus jedoch auf der Erweiterung des gesamten Trainingsdatensatzes, während in dieser Arbeit speziell Extremszenarien künstlich erweitert wurden, um Extremwerte präziser vorhersagen zu können. Eine Schätzung der Residuen zur Bestimmung der Wahrscheinlichkeit von Abweichungen einer Prognose (Abschnitt 4.2.2) wurde in [17] für eine LSTM-Prognose der Einspeisung von Windkraftanlagen durchgeführt. Anders als in dieser Arbeit wurden die Residuen dort mit einem neuronalen Feed-Forward Netz approximiert.

Hinsichtlich der Sensitivitätsanalyse und der Kriterien zum optimalen Platzieren von Messgeräten (Abschnitt 4.3) liefert [18] detaillierte Erkenntnisse. Jedoch wurden hierbei konkrete Strategien zur Platzierung von Messgeräten entworfen, die anschließend im Hinblick auf die Zustandsschätzung bewertet werden. Der in dieser Arbeit verfolgte Ansatz dreht diese Logik um. Zunächst werden für zufällige Platzierungen die Ergebnisse einer Zustandsschätzung berechnet. Anhand dieser Ergebnisse können anschließend Strategien entwickelt werden, die eine sinnvolle Platzierung von Messgeräten definieren.

Insgesamt zeichnet sich die Arbeit durch eine Verknüpfung und Spezifizierung von Verfahren aus, die auf diese Weise noch nicht zusammengebracht wurden. Die Verwendung von realen Netz- und Messdaten hebt sich zudem von vielen anderen Ansätzen ab, bei denen künstliche Netze oder synthetische Daten verwendet wurden.

3 Datenbasis

Die nachfolgend beschriebenen Ergebnisse beziehen sich auf einen Mittelspannungsnetzabschnitt eines kleinstädtischen Verteilnetzbetreibers. Im Netzabschnitt befinden sich 14 Stationen, an denen Industriebetriebe, Privatverbraucher und eine große Photovoltaikanlage (PV-Anlage) angeschlossen sind. Für alle Stationen und für den zum Netzgebiet gehörenden Abgang am Umspannwerk (UW) liegen Wirk- und Blindleistungsmesswerte für das gesamte Jahr 2022 in 15-minütiger Auflösung vor. Für alle Stationen liegen zudem Informationen zur jeweiligen Verbraucherstruktur vor. Diese ergibt sich durch die vom Netzbetreiber hinterlegte Anzahl an Standardlastprofilen H0, G1, ..., G7, L0 [19], sowie die Anzahl an Wärmepumpen, PV-Anlagen und Kunden mit registrierender Leistungsmessung (RLM-Kunden) an den Stationen.

4 Ergebnisse

Nachfolgend werden die Ergebnisse der Netzzustandsprognose für den Folgetag aufgezeigt. Zunächst wird die Performance des sogenannten Basismodells analysiert. Anschließend wird untersucht, wie die strukturelle Unterschätzung hoher Leitungsauslastungen und extremer Knotenspannungen behoben werden kann. Zum Schluss wird die Sensitivität des Modells im Hinblick auf die Qualität der zugrundeliegenden Datenbasis untersucht.

4.1 Basismodell

Zunächst wird ein grundlegendes Modell definiert, das im weiteren Verlauf als Basismodell bezeichnet wird. Zum einen dienen die Ergebnisse dieses Modells als Vergleichswerte für die im späteren Kapiteln 4.2 und 4.3 dargestellten Erweiterungen der Vorgehensweise. Zum anderen können eben diese Erweiterungen durch Schwächen dieses Modells motiviert werden.

Für das Basismodell wird angenommen, dass die Messdaten an den 14 Netzstationen als historische Messwerte vorhanden sind, diese aber nicht live an den Netzbetreiber übermittelt werden. Die einzigen Messreihen, die live übermittelt werden, sind die Wirk- und Blindleistungsverläufe am UW. Die Trainings- und Validierungsdaten für die Modelle 1 und 2 (vgl. 2.1) sind die Messwerte von Januar bis einschließlich Mai und von Juli bis einschließlich November des Jahres 2022. Getestet werden die Modelle mit den Daten der Monate Juni und Dezember desselben Jahres.

4.1.1 Bewertung des Modells 1

Die Architektur von Modell 1 wird mithilfe eines sogenannten Hyperband-Tuners optimiert, der basierend auf randomisierter Suche die Modellhyperparameter (Anzahl an Schichten und Anzahl an Zellen pro Schicht) optimiert [20]. Die vom Hyperband-Tuner bestimmte beste Architektur besteht aus zwei LSTM-Schichten mit je 64 bzw. 96 Zellen, die durch eine Dropout-Schicht getrennt sind. Anschließend folgt eine vollständige Schicht mit 192 Neuronen, bevor die Output-Schicht die gewünschte Ausgabedimension (92x2) herstellt. Dieses und alle weiteren neuronalen Netze in dieser Arbeit wurden mithilfe der Python-Bibliothek TensorFlow implementiert [21]. Das Modell liefert auf der Testmenge einen mittleren quadratischen Fehler von 0,0062 für die Prognose der UW-Messreihen. Um diesen Fehler besser interpretieren zu können, werden in Abbildung 2 die absoluten Abweichungen und beispielhafte Prognosezeitreihen für Wirk- und Blindleistung über 10 Tage dargestellt. Anhand der absoluten Abweichungen (Boxplots) ist zu erkennen, dass die Prognoseabweichungen in der Regel gering sind (Median für Wirkleistung: 0,036; Median für Blindleistung: 0,043). Es zeigt sich allerdings, dass vereinzelt auch große Abweichungen (um etwa maximal 0,5) auftreten, die auch in der beispielhaften Prognosezeitreihe (Abbildung 2, rechts) ab dem Zeitschritt 500 zu erkennen sind.

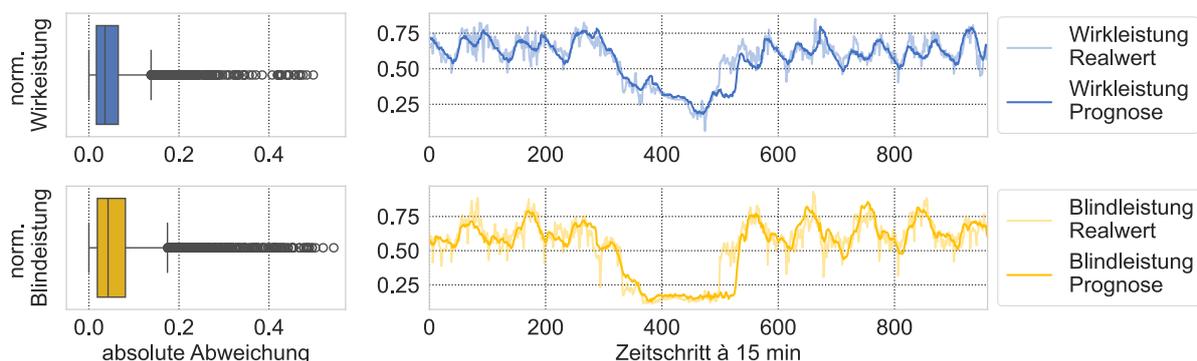


Abbildung 2: Prognosequalität von Modell 1. Oben: Boxplot der absoluten Abweichungen der Wirkleistungsprognose vom Realwert (links) und beispielhafte Prognose für 10 Tage aus dem Testdatenzeitraum (rechts). Unten: Boxplot der absoluten Abweichungen der Blindleistungsprognose vom Realwert (links) und beispielhafte Prognose für 10 Tage aus dem Testdatenzeitraum (rechts).

4.1.2 Bewertung des Modells 2

Hinsichtlich Modell 2 wird bei der Abweichungsanalyse zwischen den Leitungsauslastungen und den Knotenspannungen unterschieden. Hierfür wird das Modell 2 zweigeteilt und besteht aus einem neuronalen Feed-Forward Netz zur Bestimmung der Leitungsauslastungen und einem separaten Netz für die Knotenspannungen. Die Architektur beider Modelle wird analog zum Modell 1 durch einen Hyperband-Tuner optimiert.

Um die Fehler der Modelle bewerten zu können wird nicht die mittlere quadratische Abweichung angegeben, sondern die mittlere absolute prozentuale Abweichung (Mean Absolute Percentage Error: MAPE). Dies folgt aus der Erkenntnis, dass die Leitungsauslastungen an jeder Leitung in unterschiedlichen Wertebereichen liegen. Beispielsweise sind die Auslastungen an der Anfangsstrecke immer deutlich höher als die an der Leitung vor der Trennstelle im Netz. Analog liegen die Knotenspannungen an einer einzelnen Station in einem Wertebereich, der sich von denen der anderen Stationen unterscheiden kann. Seien $\text{range}(a_{l_i})$ der Wertebereich der Leitungsauslastungen der Leitung l_i und $\text{range}(u_{v_i})$ der Wertebereich der Knotenspannungen an Knoten v_i für den Zeitraum der Trainings- und Validierungsdaten. Dann werden die MAPEs für eine Menge an T Zeitschritten entsprechend der folgenden beiden Formeln berechnet:

$$MAPE_A = \frac{1}{T} \cdot \sum_{t=1}^T \frac{1}{m} \cdot \sum_{i=1}^m \frac{|a_{l_i}(t) - \hat{a}_{l_i}(t)|}{\text{range}(a_{l_i})}, \quad MAPE_U = \frac{1}{T} \cdot \sum_{t=1}^T \frac{1}{n} \cdot \sum_{i=1}^n \frac{|u_{v_i}(t) - \hat{u}_{v_i}(t)|}{\text{range}(u_{v_i})}$$

Diese sind bezüglich des Testdatenzeitraums von Juni und Dezember aus dem Jahr 2022 in Abbildung 3 dargestellt. Die oberen beiden Boxplots beziehen sich auf die Abweichungen bei der Berechnung der Leitungsauslastungen.

Die prozentuale Auslastung der Leitungen wurden beim Training des Modells 2 nicht skaliert. Auf diese Weise legt das Modell eine höhere Gewichtung auf diejenigen Leitungen, die stärker ausgelastet sind. Dies zeigt sich dadurch, dass der MAPE bei der Schätzung der Auslastungen der ersten vier Leitungsabschnitte (Leitungsanfangsstrecken) deutlich geringer ist als bei der Gesamtmenge an Leitungen. Durch eine einheitliche Skalierung der Auslastungswerte der einzelnen Leitungen könnte dies behoben werden. Da die Leitungsanfangsstrecken jedoch diejenigen sind, die für den Netzbetreiber im Hinblick auf die Auslastungen relevant sind, wurde keine Skalierung durchgeführt. Somit kommt es vor, dass bei Leitungen, die weniger ausgelastet sind (z. B. nur um 5 %) ein Schätzfehler von bis zu 25 % des Wertebereichs auftritt. Da dies jedoch nur eine absolute Abweichung von 1,25 % vom Realwert bedeutet, ist selbst ein so hoher MAPE zu vernachlässigen. Auf diese Weise liegt der Median absoluten prozentualen Abweichungen bezüglich aller Leitungen bei 1,4 % und die maximale Abweichung bei 24,8 %. Der Median der absoluten prozentualen Abweichungen bezüglich der Anfangsstrecken liegt bei 0,6 % und die

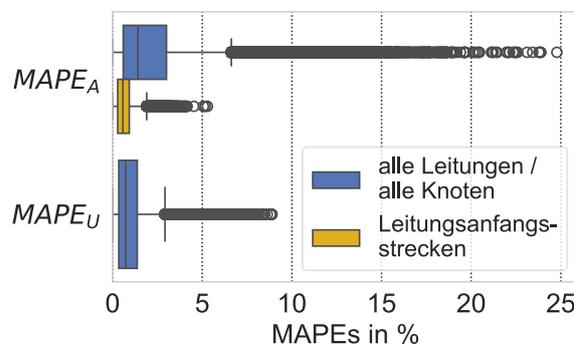


Abbildung 3: Mittlere absolute prozentuale Abweichungen von Modell 2. Oben: Leitungsauslastungen unterschieden zwischen der gesamten Leitungsmenge und der Menge der 4 Anfangsstrecken. Unten: Knotenspannungen.

maximale Abweichung bei 5,3 %. Hinsichtlich der Knotenspannungen kann keine Unterscheidung in der Relevanz der Knoten getroffen werden. Daher werden die einzelnen Spannungen vor dem Training des Modells 2 auf den Wertebereich [0,1] skaliert. Aus Abbildung 3 geht hervor, dass der Median der absoluten prozentualen Abweichungen für die Schätzung der Spannungen bei 0,8 % und das Maximum bei 8,9 % liegt.

Während die MAPEs gute Auskunft darüber liefern, wie gut das Modell 2 arbeitet, sind die prozentualen Abweichung schwer zu interpretieren. Aus diesem Grund werden zudem die mittleren absoluten Abweichungen (Mean Absolute Error: MAE) berücksichtigt. Diese zeigen klar, in welchem Bereich der Fehler liegt, der vom Modell verursacht wird. Die MAEs für einen Menge von T Zeitpunkten ist wie folgt definiert:

$$MAE_A = \frac{1}{T} \cdot \sum_{t=1}^T \frac{1}{m} \cdot \sum_{i=1}^m |a_{i_t}(t) - \hat{a}_{i_t}(t)|, \quad MAE_U = \frac{1}{T} \cdot \sum_{t=1}^T \frac{1}{n} \cdot \sum_{i=1}^n |u_{v_i}(t) - \hat{u}_{v_i}(t)|$$

Die MAEs auf der Testmenge aus Juni und Dezember sind in Abbildung 4 dargestellt. Der Median der absoluten Abweichungen für die gesamte Leitungsmenge liegt bei 0,1 %, die maximale Abweichung bei 3,1 %. Dagegen sind die Abweichungen auf den Leitungsanfangsstrecken fast nie größer als 1 %, der Median bleibt jedoch unverändert. Der Median der absoluten Abweichungen für die Knotenspannungen liegt bei 0,3 V und die maximale Abweichung 5,9 V.

Insgesamt weist das Modell 2 eine präzise Berechnungsgenauigkeit auf. Die aufgezeigten Abweichungen liegen in einem vertretbaren Bereich. Im Hinblick auf die Leitungsauslastungen ist insbesondere bei den relevanten Leitungsanfangsstrecken eine gute Performance festzustellen. Wenngleich in dieser Arbeit eine Zustandsprognose für den Folgetag beschrieben wird, kann das Modell 2 eigenständig und ohne Änderung als Netzzustandsschätzung in der Live-Betriebsführung verwendet werden. Die diskutierten Abweichungen liegen im zulässigen Rahmen, der in [18] definiert wird.

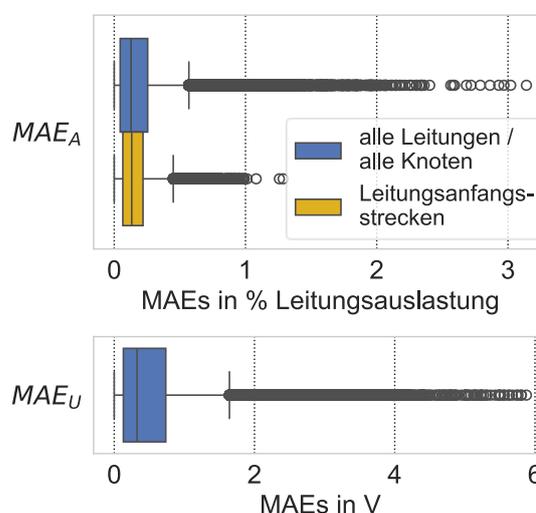


Abbildung 4: Mittlere absolute Abweichungen von Modell 2. Oben: Leitungsauslastungen unterschieden zwischen der gesamten Leitungsmenge und der Menge der 4 Anfangsstrecken. Unten: Knotenspannungen.

4.1.3 Bewertung der Modellverkettung

Zuletzt werden nun die Ergebnisse der Day-Ahead Prognose, also der Verkettung der Modelle 1 und 2 dargestellt und bewertet. Hierfür werden die absoluten Abweichungen der Prognose vom tatsächlichen Wert analysiert (Abbildung 5 oben). Hinsichtlich der Leitungsauslastungen werden neben den Gesamtabweichungen zusätzlich die Fehler auf den Leitungsanfangsstrecken betrachtet. Auf diesen Anfangsstrecken liegt der Fehler in der Regel unter 5 % (Median 1,0 %), es treten jedoch Abweichungen bis maximal 13,6 % auf. Die Fehler auf der Gesamtmenge weisen dieselben maximalen Fehler auf, im Mittel sind sie jedoch deutlich geringer (Median 0,37 %), da viele der Leitungen besonders am Strangende nur gering ausgelastet sind. Hinsichtlich der Knotenspannungen liegen die Abweichungen in der Regel unter

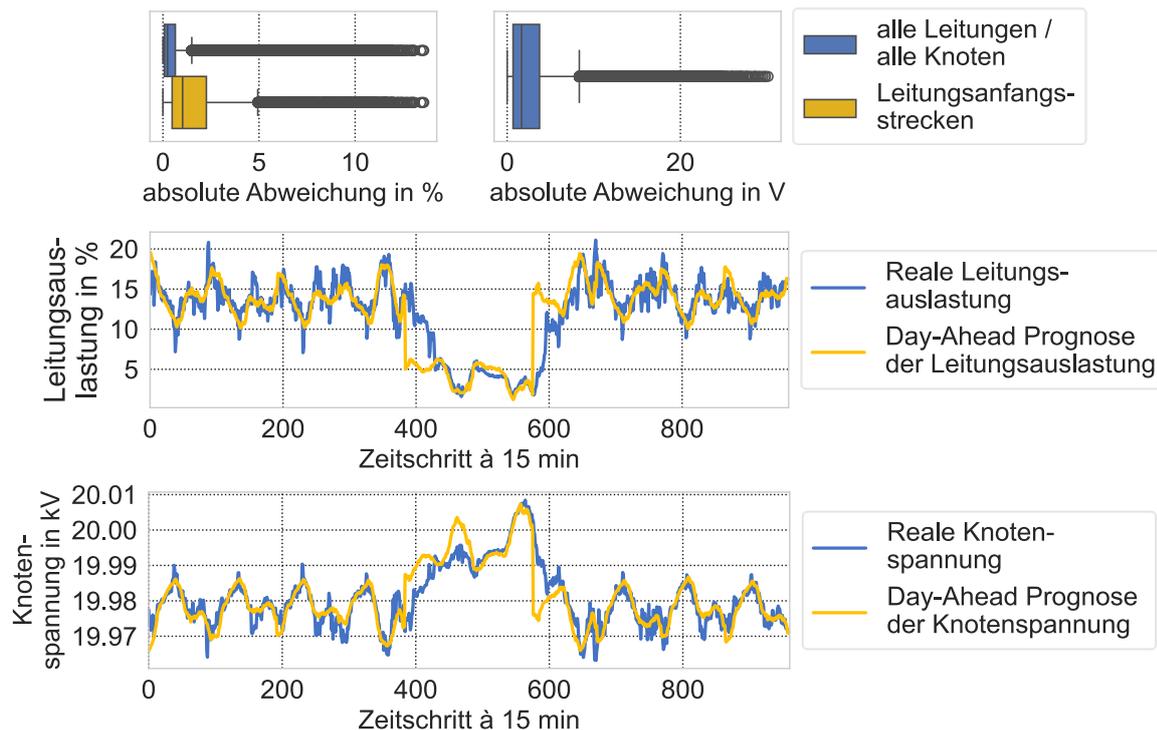


Abbildung 5: Bewertungsergebnisse der Modellverketzung von Modell 1 und Modell 2. Oben: Absolute Abweichungen bei der Prognose der Leitungsauslastungen und Knotenspannungen. Mitte: Beispielhafter Prognoseverlauf der Leitungsauslastung für 10 Tage. Unten: Beispielhafter Prognoseverlauf der Knotenspannung für 10 Tage.

7 V (Median 1,7 V), die maximale Abweichung liegt bei 30,1 V. Für zehn Beispieltage aus der Testmenge werden die Prognoseergebnisse mit dem Realwert verglichen (Abbildung 5 Mitte und unten). Dies ermöglicht eine Einordnung der Abweichungen. Hierbei zeigt sich, dass die Prognose in der Regel eine Art Mittelwert des tatsächlichen Verhaltens prognostiziert, der als guter Ausgangspunkt für Planungen im Netz dienen kann. Es zeigt sich allerdings auch, dass die Prognose zu gewissen Zeiten (um den Zeitschritt 400 und den Zeitschritt 600) deutlich vom Realwert abweichen kann. Für das Verteilnetz wird in [18] für eine Zustandsschätzung im Live-Betrieb eine Genauigkeit der Schätzung im Bereich $\pm 5\%$ bei den Leitungsauslastungen und eine Genauigkeit von $\pm 1\%$ der Nennspannung für die Knotenspannungen gefordert. Obwohl an dieser Stelle eine Prognose für den Folgetag und keine Live-Schätzung durchgeführt wurde, erfüllt die Prognose der Spannungen dieses Kriterium ($\pm 1\%$ entsprechen ± 200 V). Im Hinblick auf die Leitungsauslastungen überschreiten einige Prognosen die $\pm 5\%$ Schwelle, in etwa 98 % aller Zeitschritte in der Testmenge weichen die Prognosen allerdings um weniger als 5 % vom Realwert ab. Dies zeigt, dass die beschriebene Zustandsprognose in der Regel als zuverlässiges Werkzeug für die Einschätzung des Netzzustands von morgen dienen kann.

4.2 Vermeidung von Abweichungen in Spitzenwerten

Aus den Abweichungsanalysen des Kapitels 4.1, beispielsweise anhand der ersten 300 Zeitschritte der Abbildung 5 (Mitte und unten), geht hervor, dass die Leitungsauslastungen und Knotenspannungen in Zeiten von besonders niedriger oder hoher Auslastung bzw. Spannung strukturell unter- bzw. überschätzt werden. Dies liegt am Trainingsverfahren der Modelle: Hier werden die Gewichtungen der einzelnen Parameter in der neuronalen Netzarchitektur derart gewählt, dass die Abweichungen der Outputs auf einer im Training nicht berücksichtigten

Menge an Daten (Validierungsdaten) für die gewählte Verlustfunktion (MSE) minimiert werden. Da Extrema nur selten auftreten, unter- bzw. überschätzt das Modell diese strukturell und erzielt somit auf der Gesamtmenge an Validierungsdaten eine minimale Abweichung.

Da der Netzzustand bei (lokalen) Extrema für die Netzbetreiber am bedeutsamsten ist, wird nachfolgend beschrieben, wie diese Extremwerte besser prognostiziert werden können. Hierfür werden zwei Ansätze aufgezeigt, von denen sich einer auf Modell 1 und der andere auf Modell 2 beziehen. Anschließend wird analysiert, wie sich eine Integration dieser beiden Verfahren in der Netzzustandsprognose auf das Schätzverhalten in Extremwerten auswirkt.

4.2.1 GAN-Erweiterung von Extremszenarien (Modell 2)

Der erste Ansatz zielt auf das Modell 2 ab. Die Idee besteht darin, die Gewichtung in den Trainingsdaten zu verändern. Werden nur reale Wirk- und Blindleistungsszenarien verwendet, um die Netzberechnungen durchzuführen, liegen nur wenige Extremszenarien darin vor. Somit liegen im Trainingsdatensatz für Modell 2 ebenfalls nur wenige extreme Szenarien vor, weswegen diese im Trainingsverfahren tendenziell unter- bzw. überschätzt werden. Durch eine künstliche Vervielfältigung der extremen Szenarien und eine Integration dieser in den Trainingsdaten wird die Gewichtung verschoben.

In Abbildung 6 werden die Extremszenarien dargestellt, die im Hinblick auf Leitungsauslastungen (links) und die Knotenspannungen (rechts) ausgewählt werden. Hier zeigt sich, dass die Wirkleistung als guter Indikator dafür verwendet werden kann, ob ein Szenario extrem ist oder nicht. Liegt ein hoher Gesamtverbrauch im Netzabschnitt vor und ist die damit verbundene Summe aller Wirkleistungen hoch, so ist die Summe aller Leitungsauslastungen ebenfalls hoch. Aus diesem Grund werden im Hinblick auf die Leitungsauslastungen diejenigen Szenarien ausgewählt und vervielfältigt, an denen ein Gesamtverbrauch vorliegt, der im 90 %-Perzentil aller Gesamtverbräuche liegt. Umgekehrt zeigt sich, dass besonders niedrige bzw. hohe Knotenspannungen (Summe aller Spannungen) dann vorliegen, wenn der Gesamtverbrauch besonders hoch bzw. niedrig ist. Für die Knotenspannungen werden daher die Szenarien ausgewählt, bei denen die Summe der Wirkleistung im 90 %-Perzentil bzw. im 10 %-Perzentil liegen.

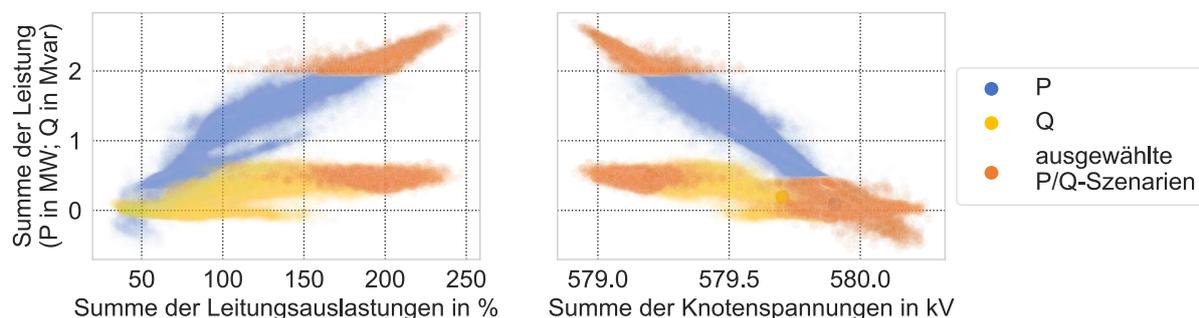


Abbildung 6: Links: Auswahl für die extremen Leitungsauslastungen. Rechts: Auswahl für die extremen Knotenspannungen.

Nach der Auswahl der Szenarien werden diese mithilfe eines Generative Adversarial Network (GAN) [22] künstlich vervielfältigt. Hierfür lernt das GAN die Verteilung der extremen Szenarien und generiert nach der Lernphase neue Szenarien, die denen der Trainingsdaten ähneln. Um zu prüfen, ob die generierten Szenarien realistisch sind, wurden diese anhand von drei Bewertungskriterien untersucht. Es wird geprüft, ob die Wertebereiche der künstlichen Szenarien

mit den realen übereinstimmen, ob die paarweisen Korrelationen zwischen den einzelnen Messreihen erhalten bleiben und ob die zweidimensionale Einbettung eine ähnliche Form hat. Es zeigt sich, dass alle drei Prüfkriterien zu einem zufriedenstellenden Maß erfüllt sind. Diese können im Appendix unter 7I eingesehen werden.

Durch das GAN können beliebig viele extreme Wirk- und Blindleistungsszenarien erzeugt werden. Die Anzahl wird als Hyperparameter behandelt und im späteren Verlauf optimiert. Für die Szenarien werden im Anschluss Netzberechnungen durchgeführt. Die Ergebnisse hieraus werden dann zusätzlich zu den Netzberechnungsergebnissen mit Realdaten als Trainingsdaten für Modell 2 verwendet. In Tabelle 1 und Abbildung 7 sind die Auswirkungen der Szenarien-Erweiterung im Hinblick auf die Leitungsauslastungsextremwerte dargestellt. Hier wurden jeweils unterschiedliche Kriterien in Abhängigkeit der Anzahl an beim Training verwendeten künstlichen Daten untersucht. Insgesamt wurde ein Jahr (35.040 Zeitschritte) an Extremszenarien generiert. In der Analyse wird dann sukzessive ein Monat (~2.900 Zeitschritte) extremer Trainingsdaten zu der realen Trainingsdatenmenge hinzugefügt, bis am Ende die gesamten generierten Daten verwendet werden. Die Testmenge, anhand derer die Kriterien untersucht werden bleibt unverändert die Menge der Realdaten aus dem Juni und Dezember 2022.

In Tabelle 1 zeigt sich, dass der MSE auf der gesamten Testmenge mit zunehmender Anzahl an künstlichen Daten tendenziell zunimmt. Dies folgt wohl aus der Tatsache, dass die künstlichen Daten nur den extremen Teil der realen Daten abbilden. Nimmt der Anteil an künstlichen Daten zu, wird die Schätzung auf den nicht extremen Realdaten schlechter. Hinsichtlich der in der Testmenge vorhandenen extremen Szenarien kann jedoch festgestellt werden, dass die Anzahl der Unterschätzungen extremer Leitungsauslastungen (> 0 %) tendenziell abnimmt. Der Anteil der starken Unterschätzungen (> 0,2 %) geht mit zunehmenden künstlichen Trainingsdaten klar zurück. Beispielhaft werden in Abbildung 7 die Abweichungsverteilungen ohne künstliche Daten und mit 12 Monaten

Tabelle 1: Fehlerveränderung und prozentualer Anteil an Spitzenwertunterschätzungen bei sich verändernder Anzahl (in Monaten) an Extremszenarien, die beim Training von Modell 2 miteinbezogen wurden.

Anzahl Monate mit künstlichen Extremszenarien	MSE auf der gesamten Testmenge	Extremszenarien in der Testmenge		
		MSE	$a_i(t) - \hat{a}_i(t) > 0 \%$	$a_i(t) - \hat{a}_i(t) > 0,2 \%$
0	0,052	0,047	56,9 %	21,4 %
1	0,062	0,051	50,0 %	13,9 %
2	0,063	0,042	49,0 %	10,9 %
3	0,061	0,034	47,3 %	10,5 %
4	0,060	0,036	41,6 %	6,2 %
5	0,066	0,029	44,3 %	6,7 %
6	0,069	0,026	45,0 %	5,0 %
7	0,076	0,034	43,0 %	5,6 %
8	0,085	0,034	38,3 %	5,4 %
9	0,079	0,029	38,8 %	4,3 %
10	0,091	0,024	43,7 %	4,6 %
11	0,088	0,031	41,4 %	4,3 %
12	0,098	0,027	37,6 %	3,7 %

künstlichen Daten auf der gesamten Testmenge und gesondert auf den extremen Szenarien der Testmenge dargestellt. In dieser Abbildung wurden die Abweichungen einer Anfangsstreckenleitung untersucht. Zum einen ist erkennbar, dass die Verteilung aller Abweichungen mit künstlichen Daten breiter ausfällt als ohne (hellgelb im Vergleich mit hellblau), d. h. die Abweichungen auf der gesamte Testmenge werden größer. Zum anderen

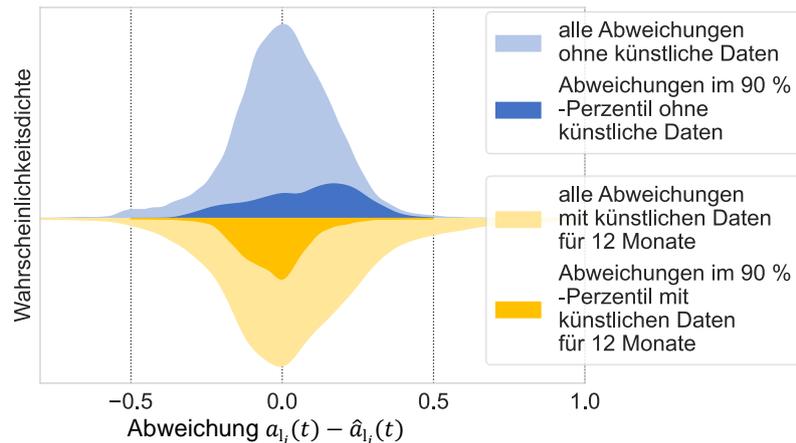


Abbildung 7: Abweichungsverteilung hinsichtlich der Leitungsauslastung aller Auslastungen und der Auslastungen im 90 %-Perzentil. Blau: Abweichungen ohne künstliche Extremszenarien. Gelb: Abweichungen bei Hinzunahme von 12 Monaten extremer Szenarien.

zeigt sich, dass sich die Abweichungsverteilung in Extremfällen durch die Hinzunahme von künstlichen Daten vom positiven Bereich (Unterschätzung) in den neutralen bis leicht negativen Bereich (leichte Überschätzung) bewegt (dunkelgelb im Vergleich mit dunkelblau). Im Hinblick auf die Knotenspannungen sind analoge Ergebnisse festzustellen. Bei der Knotenspannung muss jedoch zusätzlich zwischen extrem niedriger Spannung und extrem hoher Spannung unterschieden werden. Extrem niedrige Spannungen werden ohne künstliche Daten tendenziell überschätzt, mit künstlichen Daten kann dies jedoch reguliert werden. Dagegen verhält sich das Verfahren im Hinblick auf extrem hohe Spannungen analog zu den Leitungsauslastungen.

Die Auswirkungen der GAN-Vervielfältigung der Extremszenarien führen zu einem Trade-Off. Die Unter- bzw. Überschätzung der Extrempunkte kann auf Kosten der Schätzgenauigkeit in den nicht extremen Fällen verringert werden. Liegt die Priorität darauf, dass keine möglichen Überlastungen und Spannungsbandverletzungen übersehen werden, sollte eine hohe Anzahl an künstlichen Daten verwendet werden (z. B. ein Jahr). Soll der Netzzustand allgemein möglichst genau abgebildet werden, ist eine geringere Anzahl an künstlichen Daten geeigneter, da der MSE dadurch kleiner ist.

4.2.2 KDE-Schätzung der Residuen (Modell 1)

Hinsichtlich Modell 1 kann eine Unterschätzung von Lastspitzen durch die Berücksichtigung der beobachtbaren Prognoseabweichungen auf der Testmenge (Residuen) vermieden werden. Hierfür wird die Verteilung der Abweichungen $m_{v_i}(t) - \hat{m}_{v_i}(t)$ der Messwertprognose vom tatsächlichen Wert mit einer Kern-Dichte-Schätzung (Kernel Density Estimation: KDE) [23] berechnet. Auf diese Weise kann die Wahrscheinlichkeit approximiert werden, dass die Prognose $\hat{m}_{v_i}(t)$ vom tatsächlichen Wert $m_{v_i}(t)$ um den Wert $\Delta m_{v_i}(t)$ abweicht. Bestimmt wird somit eine Funktion

$$p_{v_i}(t, \hat{m}_{v_i}(t), \Delta m_{v_i}(t)) = \mathbb{P}[m_{v_i}(t) \geq \hat{m}_{v_i}(t) + \Delta m_{v_i}(t)]$$

für jeden Knoten v_i und Zeitpunkt t . Die Zeitpunkte liegen im Bereich 1, ..., 96. Die KDE berücksichtigt dadurch, ob eine Prognose am Anfang oder am Ende einer 24 h Prognose liegt.

Zur Approximation der Wahrscheinlichkeitsdichte der Residuen wird eine KDE mit Gauß'schen Kernen verwendet. Diese nähert die tatsächliche Verteilung durch eine Kombination unterschiedlicher Normalverteilungen an. Die optimale Bandbreite wird für jeden Zeitschritt einzeln mit Hilfe einer Rastersuche ermittelt. Beispielhaft visualisiert Abbildung 8 die Abweichungsverteilung rund um eine Prognose der Wirkleistung.

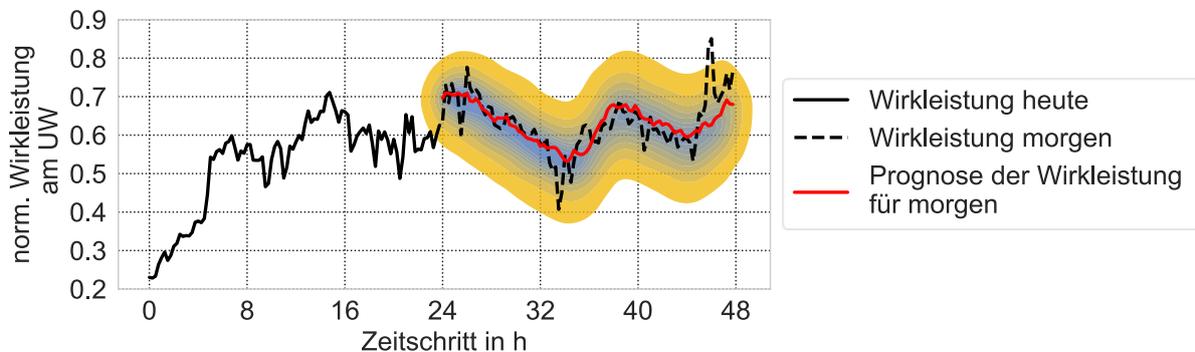


Abbildung 8: Prognose der Wirkleistung durch Modell 1. Die farbliche Hinterlegung visualisiert anhand der geschätzten Verteilung der Residuen, wie wahrscheinlich eine Abweichung von dieser Prognose ist. Hohe Wahrscheinlichkeit (blau) und geringe Wahrscheinlichkeit (gelb), dass eine Abweichung in diesem Bereich liegt.

Um bei der Prognose auch die extremen Lastspitzen bzw. -täler zu treffen, wird nicht nur die Prognose für den Folgetag betrachtet, sondern zudem Abweichungs-Quantile, die anhand der geschätzten Verteilung bestimmt werden. Um die Lastspitzen nicht strukturell zu unterschätzen, bietet sich der Übergang zu einem hohen (z. B. 90 %-) Quantil an. Hierdurch werden auf die Prognose noch der Wert des Quantils aufaddiert. Nachfolgend sind die Auswirkungen der unterschiedlichen Quantile abgebildet. Hierbei wird zwischen den Lastspitzen (links) und Lastsenken (Mitte) unterschieden.

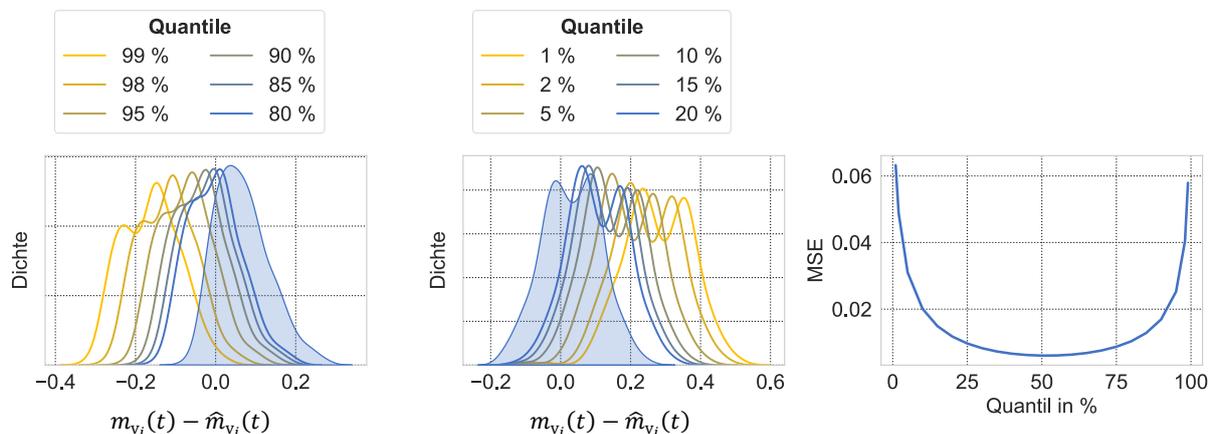


Abbildung 9: Auswirkungen der Addition von Quantil-Werten auf die Prognosewerte im Hinblick auf Lastspitzen und Lastsenken der Wirkleistung. Links: Veränderung der Abweichungen bei großen Wirkleistungswerten (Ausgangspunkt ohne Quantil-Addition: blaue Fläche). Mitte: Veränderung der Abweichungen bei kleinen Wirkleistungswerten (Ausgangspunkt ohne Quantil-Addition: blaue Fläche). Rechts: MSE auf der gesamten Trainingsdatenmenge in Abhängigkeit des gewählten Quantils.

Erkennbar ist, dass durch den Übergang zu einem hohen Quantil die Unterschätzung von Lastspitzen nahezu vollständig vermieden werden kann. Ebenso kann durch den Übergang zu einem niedrigen Quantil die Überschätzung von besonders niedrigen Lasten verhindert werden. Zugleich führt der Übergang zu einem extremen Quantil dazu, dass der MSE deutlich zunimmt (Abbildung 9 rechts). Analog zur GAN-Vervielfältigung extremer Szenarien liegt somit

auch bei der KDE-Schätzung der Residuen ein Trade-Off zwischen der der Gesamtgenauigkeit und der Vermeidung einer Unter- bzw. Überschätzungen von Spitzen vor.

4.2.3 Optimale Hyperparameterwahl

Nach der Darstellung der zwei Verfahren zur Vermeidung von Spitzenunter- bzw. überschätzung wird nun diskutiert, wie die Hyperparameter bei diesen Verfahren optimal gewählt werden können, sodass die Verkettung der Modelle 1 und 2 einerseits eine gute allgemeine Prognosequalität, andererseits eine hohe Treffergenauigkeit in den Spitzenwerten aufweist. Bei der GAN-Vervielfältigung ist der Hyperparameter gegeben durch die Anzahl der künstlichen Extremszenarien, die im Training von Modell 2 berücksichtigt werden. Bei der KDE der Residuen ist der zu optimierende Hyperparameter das Quantil, das bei der Prognose verwendet wird, um Über- bzw. Unterschätzungen zu vermeiden. Bei der kombinierten Anwendung von Modell 1 und Modell 2, unter Einbeziehung sowohl der KDE-basierten Schätzung der Residuen als auch der GAN-gestützten Erweiterung der Extremszenarien, zeigt sich, dass die GAN-Erweiterung frühzeitig keinen signifikanten Vorteil bietet. Es wird deutlich, dass bei Verwendung der Prognosen von Modell 1, ergänzt durch ein leicht über dem Median liegendes Abweichungs-Quantil, die Integration der Extremszenarien in das Training von Modell 2 keinen zusätzlichen Mehrwert schafft. Im Kontext der Modellverkettung erweist sich daher die alleinige Nutzung der KDE der Residuen als ausreichend. Dennoch kann, wie in Abschnitt 4.2.1 demonstriert, die GAN-basierte Erweiterung der Trainingsdaten für den isolierten Einsatz von Modell 2 im Live-Betrieb durchaus vorteilhaft sein.

Im Hinblick auf die Verkettung von Modell 1 und Modell 2 bleibt somit die Frage, welches Abweichungs-Quantil auf die Prognose von Modell 1 addiert werden sollte, sodass der Prognosefehler auf der gesamten Testdatenmenge zwar gering ist, die Unter- bzw. Überschätzung von Extremwerten jedoch möglichst vermieden wird. Das Vorgehen hierbei wird beispielhaft im Hinblick auf die Prognose der Leitungsauslastungen dargestellt. Bzgl. der Leitungsauslastungen werden für die Quantil-Werte p von 45 % bis 95 % (in 5 % Schrittwerte) jeweils zwei Kenngrößen bestimmt. Zum einen wird der MSE auf der Testmenge für dieses Perzentil berechnet. Dieser Wert wird mit $MSE(p)$ bezeichnet. Zum anderen wird berechnet, wie groß der Anteil der hohen Leitungsauslastungen (Auslastung im 90 %-Perzentil) ist, die um mindestens 2 % unterschätzt werden. Dieser Wert wird mit $U_{90}(p)$ bezeichnet. Um die Kenngrößen vergleichen zu können, werden diese jeweils auf den Wertebereich zwischen 0 und 1 normiert. Die resultierenden Größen werden mit $MSE_{\text{normiert}}(p)$ und $U_{90,\text{normiert}}(p)$ bezeichnet. Um den Trade-Off zu lösen und das optimale Quantil zu finden wird anschließend das folgende Optimierungsproblem gelöst:

$$\min_p MSE_{\text{normiert}}(p) + U_{90,\text{normiert}}(p)$$

Am Beispiel der Leitungsauslastungen wird der Trade-Off und die Berechnung des optimalen Quantils in Abbildung 10 dargestellt. In diesem Fall fällt die Wahl auf das 75 %-Quantil bei der Prognose von Modell 1 mit aufaddierten Abweichungen aus der KDE-geschätzten Abweichungsverteilung. Durch eine höhere Gewichtung eines Summanden im Optimierungsproblem kann die Hyperparameterauswahl zudem auf das jeweilige Interesse angepasst werden.

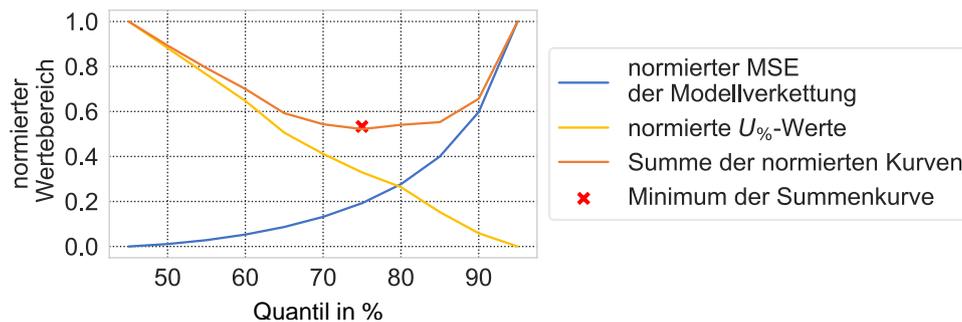


Abbildung 10: Lösung des Trade-Offs zwischen MSE der Modellverkettung und der Vermeidung von Unterschätzungen von extremen Leitungsauslastungen durch optimale Wahl des Perzentils.

4.3 Sensitivitätsanalyse

Im Folgenden wird die Sensitivität der Netzzustandsprognose im Hinblick auf die Qualität der zugrundeliegenden Datenbasis analysiert. Nach einem kurzen Überblick und einer Einführung in die Begrifflichkeiten (4.3.1) wird die Sensitivität der Modelle untersucht (4.3.2). Hieraus werden im Anschluss Rückschlüsse auf die optimale Platzierung von Messgeräten gezogen (4.3.3).

4.3.1 Notation und Überblick

Da von allen Stationen für das Jahr 2022 Wirk- und Blindleistungsmesswerte vorliegen, ist es möglich eine vollständige Sensitivitätsanalyse durchzuführen. Hierfür ist es wichtig, die Begriffe Live-Messwerte (LM) und Historische Messwerte (HM) klar zu differenzieren. Während LM im laufenden Netzbetrieb in Echtzeit an die Netzleitstelle übertragen werden, bezeichnen HM Daten, die in der Vergangenheit (z. B. mit einem mobilen Messgerät) aufgezeichnet wurden. HM können somit nicht von Modell 1 für den Folgetag prognostiziert werden, sie geben jedoch eine gute Auskunft über das Verbraucher- und Einspeiseverhalten an einer Station. HM werden bei den Netzberechnungen zur Erstellung von Trainingsdaten für Modell 2 miteinbezogen.

4.3.2 Fehlerveränderung bei Änderung der Datenbasis

Nun wird untersucht, wie sich der Prognosefehler verhält, wenn zusätzlich zu den UW-Messungen noch weitere LM vorliegen. Somit wird das Basismodell erweitert, indem durch Modell 1 weitere Messreihen für den Folgetag prognostiziert werden, und diese in Modell 2 den Input aufstocken. Zunächst wird die Fehlerveränderung in Modell 2 betrachtet. Hierfür wird der in Abbildung 11 dargestellte Prozess mit einer unterschiedlichen Anzahl an ausgewählten Stationen durchlaufen. Für jede Anzahl $k \leq 14$ wird nachfolgender

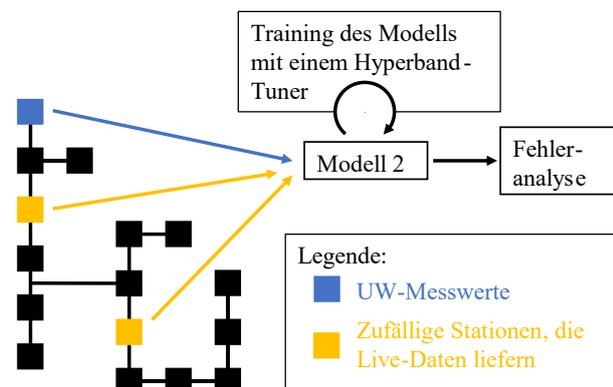


Abbildung 11: Iterationsschritt bei der Sensitivitätsanalyse von Modell 2.

Algorithmus 100-mal ausgeführt: Es werden zusätzlich zu den UW-Messwerten k zufällige Stationen ausgewählt, die LM liefern. Mit diesen LM, den Wetterdaten, der Uhrzeit und den

Kalenderinformationen wird des Modell 2 trainiert und anschließend für eine Testmenge bestehend aus den Daten aus zwei Monaten bewertet. Erneut dient die mittlere quadratische Abweichung als Verlustfunktion. Die Anzahl von 100 Wiederholungen für jedes k ergibt sich aus den folgenden Beobachtungen: Zum einen ist der Hyperband-Algorithmus zur Optimierung der Modellarchitektur berechnungsintensiv, zum anderen sollen die unterschiedlichen Auswahlmöglichkeiten für k Stationen aus den 14 Möglichen erschlossen werden. Durch 100 Wiederholungen kann einerseits die Berechnungszeit handgehabt werden, andererseits ist die Ergebnismenge aussagekräftig. Bezüglich der Bestimmung der Leitungsauslastungen verändern sich die Fehler bei unterschiedlicher Anzahl an Stationen mit LM wie in Abbildung 12 dargestellt. Der Modellfehler verringert sich mit der Anzahl an LM. Dies folgt aus der Tatsache, dass das Modell mit steigender Anzahl an LM mehr Informationen erhält und die Schätzung somit präziser wird. Außerdem wird deutlich, dass der Fehler im Bereich von wenigen LM schneller abnimmt als gegen Ende. Hieraus wird deutlich, dass die ersten LM für echte Verbesserungen sorgen, der Unterschied zwischen 10 und 14 LM allerdings zu vernachlässigen ist.

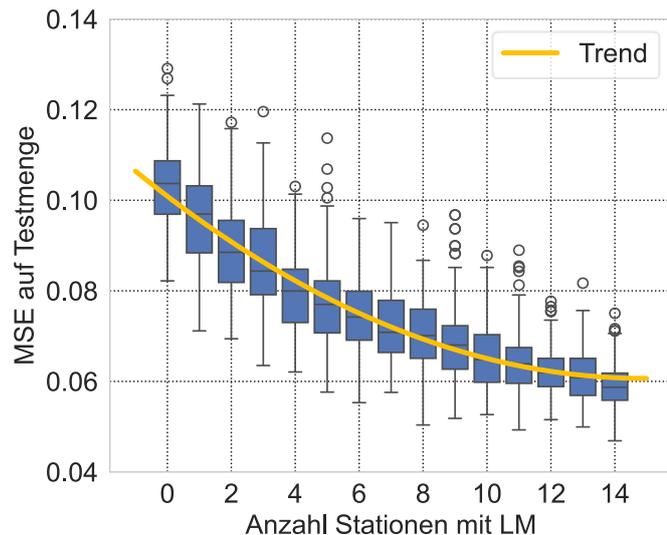


Abbildung 12: Fehlerveränderung von Modell 2 in Abhängigkeit der Anzahl an LM.

Als nächstes wird darauf eingegangen, wie sich eine veränderte Anzahl an LM auf die Prognosequalität von Modell 1

auswirkt. Im Gegensatz zum Basismodell werden nun nicht nur die Messungen am UW für die nächsten 24 h prognostiziert, sondern zusätzliche LM werden mit in die Vorhersage einbezogen. Da die einzelnen Zeitreihen aber unabhängig voneinander vorhergesagt werden, wirkt sich eine Hinzunahme weiterer Zeitreihen bei ausreichender Modellkomplexität nicht negativ auf die Prognosequalität im Hinblick auf die ursprünglichen Zeitreihen aus. Beispielsweise bleibt der MSE der Vorhersage der UW-Zeitreihen unabhängig von der Anzahl an weiteren LM etwa gleich. Es zeigt sich jedoch, dass die Wirk- und Blindleistungsverläufe an den Nicht-UW-Knotenpunkten mit größerem MSE prognostiziert werden. Dies liegt wohl daran, dass diese Verläufe volatiler sind und sich für einen Zeitraum von 24 h schlechter vorhersagen lassen als die UW-Werte, die auf einer höheren Aggregationsebene liegen.

Zum Schluss bleibt zu untersuchen, ob der geringere Modellfehler, der durch die zunehmende Anzahl an LM am Modell 2 zu erkennen ist (Abbildung 12) die in Verkettung der beiden Modelle erhalten bleibt. Hierfür werden die jeweils besten Modelle der iterativen Untersuchungen für die unterschiedlichen Anzahlen an LM ausgewählt, verkettet und in ihren Fehlern analysiert. Da die 4.1.1 beschriebene Optimierung der Parameter von Modell 1 sehr rechenintensiv ist, beschränkt sich die Analyse der Auswirkungen auf die Modellverkettung auf den Wertebereich

von 0 bis 5 LM. Hier zeigt sich, dass eine zusätzliche LM die mittleren Abweichungen bei der Prognose der Leitungsauslastungen reduzieren (Abbildung 13). Zum einen nehmen hohe Abweichungen sowohl in ihrer Anzahl wie auch in ihrer Größe mit zunehmender Anzahl an LM ab. Zum anderen nimmt auch der mittlere absolute Fehler der Leitungsauslastungsprognose mit steigender Anzahl an LM stetig ab.

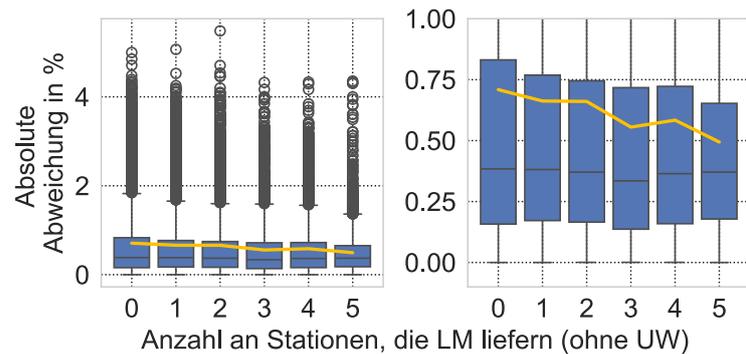


Abbildung 13: Absolute Abweichungen der Day-Ahead Leitungsauslastungsprognose in Abhängigkeit der Anzahl an Stationen, die LM liefern. Beide Abbildungen bilden dieselben Werte ab, die Abbildung rechts ist ein Zoom auf den Abweichungsbereich zwischen 0 % und 1 %. In gelb dargestellt ist der Verlauf der mittleren absoluten Abweichung.

Hinsichtlich der Prognoseabweichungen kann somit festgehalten werden, dass diese mit steigender Anzahl an LM im betrachteten Netzabschnitt abnehmen. Die Abnahmen können, wie in Abbildung 13 dargestellt, quantifiziert werden. Somit kann ein Netzbetreiber auf Basis der gewünschten Prognosegenauigkeit einsehen, wie viele Messgeräte installiert werden müssen, um diese Genauigkeit zu erreichen.

4.3.3 Geeignetes Platzieren von Messgeräten

Bei den Untersuchungen zur Sensitivitätsanalyse zeigte sich, dass die Auswahl der Stationen, die LM liefern, deutliche Auswirkungen auf die Fehlerverringerung bei Modell 2 hat (und damit auch auf die Modellverkettung). In diesem Abschnitt wird daher darauf eingegangen, welche LM für größere Verbesserungen bei Modell 2 sorgen. Auf diese Weise wird geklärt, an welchen Stationen Messgeräte eingebaut werden sollten, um eine Zustandsschätzung möglichst präzise zu implementieren. Für viele Netzbetreiber ist dies eine höchst relevante Fragestellung [24].

Anhand der in Abschnitt 4.3.2 dargestellten Simulationen können diejenigen Stationen gefunden werden, die für hohe Modellverbesserungen sorgen. Für jede mögliche Anzahl an LM wird für jede Station v_i der durchschnittliche MSE von Modell 2 berechnet, wenn v_i LM liefert. Da für jede mögliche Anzahl an LM sowohl 100 Iterationen bezüglich Leitungsauslastung als auch ebenso viele Iterationen bezüglich Knotenspannung mit beliebiger Stationsauswahl durchgeführt wurden, sind diese Durchschnittswerte insbesondere für eine niedrige Anzahl an LM aussagekräftige Größen. Da es für eine hohe Anzahl an LM sehr viele Möglichkeiten für eine zufällige Stationsauswahl gibt, sind die Durchschnittswerte in diesem Bereich womöglich ungenauer. Für eine Anzahl von einer bis fünf LM zeigt sich jedoch gut, dass immer die gleichen Stationen für niedrige Modell-MSE sorgen, wenn sie LM liefern. Es können vier Stationen ausgemacht werden, die sowohl im Hinblick auf die Leitungsauslastungen, aber auch hinsichtlich der Knotenspannung, bei allen möglichen Anzahlen an LM zu niedrigen Abweichungen führen. Jeweils eine Station existiert, die für die Leitungsauslastungen gute Ergebnisse liefert, für die Knotenspannung jedoch keinen auffälligen Mehrwert liefert und umgekehrt. Stationen, deren Auswahl zur Übermittlung von LM zu großen Verbesserungen des MSEs führen, werden im weiteren Verlauf als *gute* Stationen bezeichnet.

Um das Potenzial guter Stationen einzuordnen, wurde das in Abbildung 11 beschriebene Verfahren für die Anzahl von zwei LM weitere 100-mal durchgeführt, wobei diesmal jeweils zwei zufällige Stationen aus der Menge der fünf guten Stationen für die Leitungsauslastungsbestimmung ausgewählt wurden. Die Verteilung der MSEs bei der Auswahl von zwei zufälligen guten Stationen wird in Abbildung 14 mit der Verteilung der MSEs bei der Auswahl von zwei zufälligen Stationen aus der gesamten Stationsmenge verglichen. Es zeigt sich, dass die Abweichungen bei der Auswahl von guten Stationen deutlich geringer sind. Zum Vergleich wurde zudem noch die Verteilung der MSEs bei der Auswahl von vier zufälligen Stationen mit LM dargestellt. Abgesehen von einer leichten Abweichung ist erkennbar, dass die Verteilung der MSEs bei der Auswahl von zwei guten Stationen mit der von vier beliebigen Stationen übereinstimmt. Folglich wird mit zwei gut platzierten Messungen die gleiche Modellqualität erreicht wie bei vier zufällig platzierten. Dies ist ein bedeutsames Ergebnis im Hinblick auf die Kosten, die für ein Messgerät und dessen Einbau aufgewendet werden müssen.

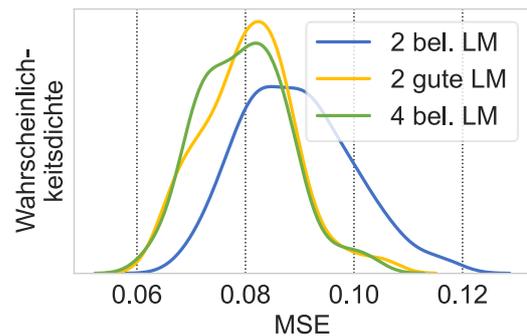


Abbildung 14: Vergleich der Verteilungen der MSEs von Modell 2 bei der Auswahl von zwei beliebigen, zwei guten und vier beliebigen Stationen.

Es bleibt zu klären, welche Eigenschaften die guten Stationen auszeichnen. Hierfür werden Kriterien beschrieben, die dafür sorgen, dass eine Station gut ist. Ein Netzbetreiber kann diese Kriterien bei der Auswahl von Stationen, an denen LM erhoben werden sollen, berücksichtigen. Diese Kriterien werden unter anderem aus den Verbraucherstrukturdaten und den Messdaten an den Stationen entwickelt. Zum einen wird die Anzahl an Haushalts-, Gewerbe- und Landwirtschaftsprofilen, sowie die Anzahl an Wärmepumpen, PV-Anlagen und RLM-Kunden an den Stationen auf den Wertebereich $[0,1]$ normiert. Anschließend wird der Durchschnittswert der einzelnen Kenngrößen für alle Stationen mit dem Durchschnitt der guten Stationen verglichen. Hier zeigt sich, dass sich die guten Stationen durch eine hohe Anzahl an Gewerbe-Profilen und RLM-Kunden auszeichnen (Abbildung 15 links). Zum anderen werden die Werte für das Maximum, das Minimum, den Mittelwert und die Standardabweichung jeweils in Wirk- und Blindleistung für jede Station erhoben und auf gleiche Weise normiert. Ein Vergleich der Durchschnittswerte aller Stationen mit denen der guten Stationen zeigt, dass die guten Stationen in allen Bereichen überdurchschnittlich hohe Werte aufweisen (Abbildung 15 rechts). Insgesamt zeigen diese Auswertungen, dass im Hinblick auf die Qualität der Zustandsprognose tendenziell Stationen vermessen werden sollten, die eine hohe Anzahl an Gewerbe- und RLM-Kunden haben und deren Wirk- und Blindleistungsmessungen folglich höhere maximale, minimale und durchschnittliche Werte aufweisen. Zudem ist die Streuung in den Messwerten überdurchschnittlich hoch.

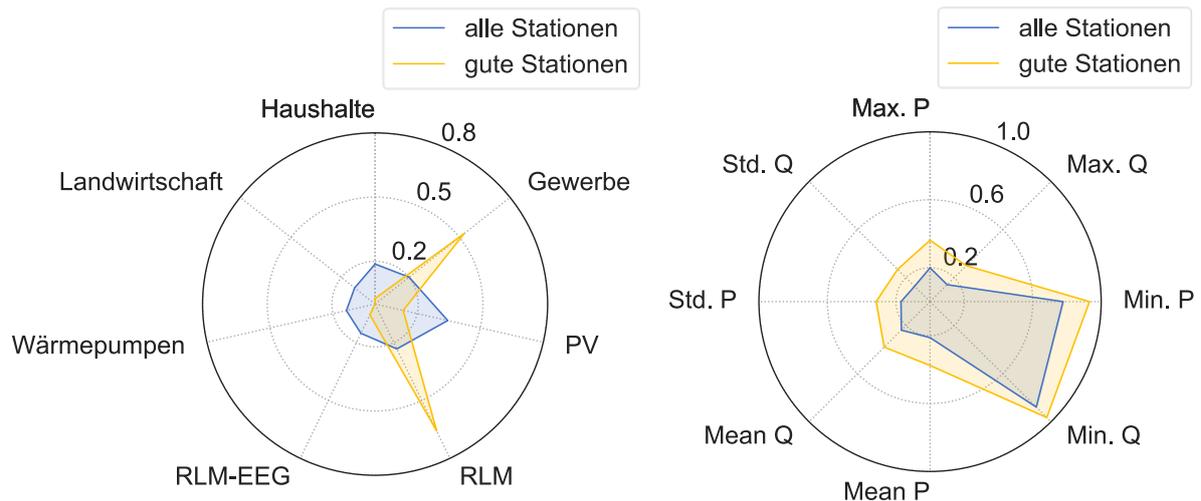


Abbildung 15: Normierte durchschnittliche Kenngrößen der gesamten Stationsmenge im Vergleich zur Menge der guten Stationen. Links: Kenngrößen basierend auf den Verbraucherstrukturdaten. Rechts: Kenngrößen basierend auf den Wirk- und Blindleistungsmessdaten.

Neben den Kenngrößen durch Verbraucherstruktur- und Messdaten wurde ein weiteres Kriterium entwickelt, durch welches sich gute Stationen charakterisieren lassen. Die zugrunde liegende Idee hierbei besteht darin, dass das Modell 2 die beste Präzision erzielt, wenn die Messwerte in den Trainingsdaten die Situation im gesamten Netzabschnitt möglichst genau abbilden. Aus diesem Grund wurden die Pearson-Korrelationskoeffizienten [25] $P(m_{v_i}, m_{v_j})$ hinsichtlich der Wirk- und Blindleistungsmessreihen

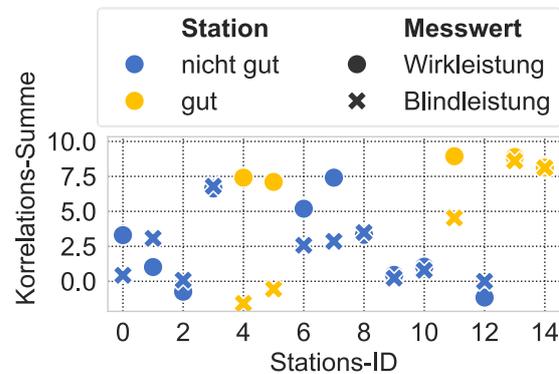


Abbildung 16: Korrelations-Summen der Stationen für Wirk- und Blindleistung.

an den Knotenpunkten v_1, \dots, v_n untersucht. Ist ein Koeffizient $P(m_{v_i}, m_{v_j})$ groß (nahe 1) bedeutet das, dass die Messreihen m_{v_i} und m_{v_j} ähnlich sind, im Sinne das ein Wert in der Messreihe m_{v_j} groß ist, wenn der Wert in m_{v_i} zur gleichen Zeit groß ist und umgekehrt. Um zu prüfen, wie stark eine Messreihe die Situation im gesamten Netzabschnitt abbildet, werden für alle Stationen Korrelations-Summen $KS(v_i)$ berechnet, bei denen die paarweisen Korrelationskoeffizienten einer Messreihe mit allen anderen Messreihen aufaddiert werden:

$$KS(v_i) = \sum_{j=1}^n P(m_{v_i}, m_{v_j})$$

Ist die Korrelations-Summe $KS(v_i)$ an Station v_i hoch, ist die Messreihe an dieser Station ähnlich zu vielen anderen Messreihen der anderen Stationen. Eine Darstellung der Korrelations-Summen für alle Stationen aufgeschlüsselt nach Wirk- und Blindleistungsmesswerten zeigt, dass die Korrelations-Summen der Wirkleistung der guten Stationen allesamt hoch sind (Abbildung 16). Dies zeigt, dass sich die guten Stationen wohl dadurch auszeichnen, dass ihre Wirkleistungsmesswerte ähnlich zu denen im gesamten Netzabschnitt sind. Dadurch sind die Messwerte an diesen Stationen repräsentativ für den gesamten Netzabschnitt und sorgen für hohe Verbesserungen bei Modell 2, wenn sie in den Trainingsdaten enthalten sind. Bei der

Auswahl der Stationen, an denen LM erhoben werden sollten, kann somit berücksichtigt werden, ob eine Station eine Verbraucherstruktur aufweist, die an anderen Stationen ebenfalls vorliegt und somit repräsentativ für diese Stationsmenge aufgenommen wird.

Zuletzt wurde noch untersucht, ob es ein Kriterium zur Charakterisierung guter Stationen gibt, das auf die netztopologische Lage zurückzuführen ist. Die für Leitungsauslastung und Knotenspannung guten Stationen liegen eine am Anfang, zwei etwa in der Mitte und eine am Ende des Netzabschnitts. Dies deutet darauf hin, dass die Messungen optimalerweise über das Netzgebiet verteilt werden sollten. Liegt der Fokus auf der Leitungsauslastung, eignet sich ein weiteres

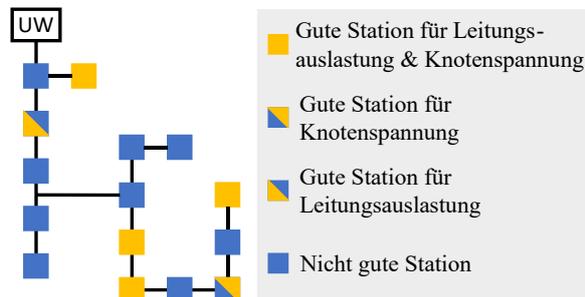


Abbildung 17: Darstellung der Positionen der guten Stationen.

Messgerät am Leitungsanfang. Knotenspannungen können besser geschätzt werden, wenn ein weiteres Messgerät am Leitungsende angebracht wird.

Insgesamt wird sich der optimale Ort zum Einbau von Messgeräten durch eine Kombination der drei Kriterien ergeben. Sofern möglich sollten Stationen ausgewählt werden, die einen hohen, variablen Verbrauch aufweisen (z. B. aufgrund von Gewerbe und RLM-Kunden), die das Verbraucher- und Einspeiseverhalten an nicht vermessenen Stationen gut repräsentieren (hohe Korrelations-Summe), und die über das gesamte Netzgebiet verteilt sind (Anfang, Mitte und Ende eines Strangs).

5 Fazit und Ausblick

Die Day-Ahead Prognose der Leitungsauslastungen und Knotenspannungen für den ausgewählte Mittelspannungsnetzabschnitt wurde mithilfe einer Verkettung zweier neuronaler Netze implementiert. Beide Modelle sind für sich genommen auf dem aktuellen Stand der Technik, ihre Verknüpfung war jedoch bislang unerforscht und offenbart enormes Potenzial. Das in Abschnitt 4.1 dargestellte Basismodell weist bei der Prognose über 24 h abgesehen von Ausreißern in aller Regel absolute Abweichungen kleiner 5 % bei den Leitungsauslastungen und kleiner 7 V bei den Knotenspannungen auf. Dies ist eine Größenordnung, die laut Literatur bei einer Live-Zustandsschätzung gewährleistet sein sollte. Die Erfüllung dieser Kriterien für eine 24 h Prognose verdeutlicht die hohe Qualität des Modells. Nichtsdestotrotz muss weiter untersucht werden, wie sich das Modell verhält, wenn nicht an allen Stationen historische Messwerte vorhanden sind. Fehlende Live-Messwerte und historische Messwerte an einer Station müssen mit sogenannten Pseudo-Messwerten approximiert werden. Prognoseergebnisse mit Pseudo-Messwerten werden derzeit analysiert und demnächst veröffentlicht.

Die strukturelle Unter- bzw. Überschätzung von Spitzenwerten kann isoliert für Modell 1 und Modell 2 durch das Anwenden der in Abschnitt 4.2 beschriebenen Verfahren auf Kosten des MSEs auf der Gesamtmenge vermieden werden. Im Hinblick auf die Modellverkettung reicht bereits die Anwendung des Verfahrens zur Schätzung der Residuen (4.2.2), eine GAN-Erweiterung von Extremszenarien (4.2.1) liefert keinen zusätzlichen Mehrwert. Durch die Lösung eines Optimierungsverfahrens wurde der optimale Hyperparameter des KDE-Verfahrens bestimmt, sodass der Trade-Off zwischen dem MSE auf der Gesamtmenge und der strukturellen

Unterschätzung von Extremwerten gelöst werden konnte. Es zeigte sich, dass die Prognose über 24 h in Verbindung mit dem 75 %-Quantil der Abweichungsverteilung die beste Parameterwahl darstellt. Das Verfahren zeichnet sich an dieser Stelle durch eine einfache Parametrierung aus, die entsprechend den Anforderungen schnell geändert werden kann. Denkbar ist auch die Vorhersage von mehreren Werten pro Leitungsauslastung und Knotenspannung. Durch die Verwendung des Medians, des 75 %-Quantils und des 90 %-Quantils, ist zum einen eine präzise Schätzung des gesamten Tages, aber auch eine Extremwertabschätzung vorhanden.

Durch die Sensitivitätsanalyse des Prognosemodells in Abschnitt 4.3 kann der Nutzen eines Messgeräts quantifiziert werden. Durch eine Festlegung der Anforderungen an das Prognosemodell und eine klare Definition der Kosten, die für ein Messgerät aufgewendet werden müssen, könnte hiermit das Kosten-Nutzen-optimale Modell bestimmt werden. Es zeigt sich außerdem, dass die Platzierung der Messgeräte einen hohen Einfluss auf die Modellqualität hat. Wenngleich in dieser Arbeit keine konkrete Platzierungsstrategie entwickelt wurde, konnten Kriterien definiert werden, die bei der Verteilung von Messgeräten berücksichtigt werden sollten. Der Einbau von Messgeräten an über dem Netzgebiet verteilten Stationen mit hohem und stark streuendem Verbrauch, deren Verbrauchs- und Einspeiseverhalten repräsentativ für andere Stationen ist, scheint sinnvoll.

6 Danksagung

Die Arbeit wurde unterstützt und finanziert durch das KI-Produktionsnetzwerk der Technischen Hochschule Augsburg, das durch die Hightech Agenda Bayern des Bayerischen Staatsministeriums für Wissenschaft und Kunst gefördert wird [26]. Durch Mess- und Netzdaten wurde diese Arbeit von den Verteilnetzbetreibern LEW Verteilnetz GmbH, SWM Infrastruktur GmbH & Co. KG und Stadtwerke Neuburg a. d. Donau unterstützt.

7 Referenzen

- [1] V. Gustedt et al., „Netzentwicklungsplan Strom 2037 mit Ausblick 2045, Version 2023: Zweiter Entwurf der Übertragungsnetzbetreiber,“ Übertragungsnetzbetreiber CC-BY-4.0, 2023. [Online], Available: <https://www.netzentwicklungsplan.de/nep-aktuell/netzentwicklungsplan-20372045-2023>. [Zugriff: 09.01.2024].
- [2] M. Klobasa et al., „Künstliche Intelligenz für die Integrierte Energiewende,“ Fraunhofer-Institut für System- und Innovationsforschung ISI, Karlsruhe, 2019.
- [3] I. Goodfellow et al., *Deep Learning: Das umfassende Handbuch: Grundlagen, aktuelle Verfahren und Algorithmen, neue Forschungsansätze*. Frechen: mitp Verlags GmbH & Co. KG, 2018.
- [4] DIgSILENT, *PowerFactory 2022*, Gomaringen, 2022.
- [5] H. Hou et al., „Review of load forecasting based on artificial intelligence methodologies, models, and challenges,“ *Electric Power Systems Research*, 210, 108067, 2022.
- [6] J. Zhu et al., „Review and prospect of data-driven techniques for load forecasting in integrated energy systems,“ *Applied Energy*, 321, 119269, 2022.
- [7] Y. Hua et al., „Deep learning with long short-term memory for time series prediction,“ *IEEE Communications Magazine*, 57(6), S. 114-119, 2019.

- [8] G. Memarzadeh und F. Keynia, „Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm,” *Electric Power Systems Research*, 192, 106995, 2021.
- [9] S. Atef und A. Eltawil, „Assessment of stacked unidirectional and bidirectional long short-term memory networks for electricity load forecasting,” *Electric Power Systems Research*, 187, 106489, 2020.
- [10] J. Menke et al., „Distribution system monitoring for smart power grids with distributed generation using artificial neural networks,” *International Journal of Electrical Power & Energy Systems*, 113, S. 472-480, 2019.
- [11] A. Winter et al., „Application of artificial neural networks for power system state estimation-validation with a weighted least squares algorithm,” In ETG Congress, 2023, S. 1-6.
- [12] K. Mestav et al., „Bayesian state estimation for unobservable distribution systems via deep learning,” *IEEE Transactions of Power Systems*, 34(6), S. 4910-4920, 2019.
- [13] A. Abur und A. Exposito, *Power system state estimation: theory and implementation*. New York: Marcel Dekker, Inc., 2004.
- [14] B. Hayes et al., „A closed-loop state estimation tool for MV network monitoring and operation,” *IEEE Transactions on Smart Grid*, 6(4), S. 2116-2125, 2014.
- [15] M. Antončič et al., „State forecasting in distribution networks,” In IEEE PES Innovative Smart Grid Technologies Europe, 2019, S. 1-5.
- [16] K. Mestav und L. Tong, „Learning the unobservable: High-resolution state estimation via deep learning,” In 2019 57th Annual Allerton Conference on Communication, Control, and Computing, 2019, S. 171-176.
- [17] M. Ko et al., „Deep concatenated residual network with bidirectional LSTM for one-hour-ahead wind power forecasting,” *IEEE Transactions on Sustainable Energy*, 12(2), S. 1321-1335, 2020.
- [18] A. Fatemi et al., „On the impact of smartification strategies for the state estimation of low voltage grids,” In IETW, 2023.
- [19] H. Meier et al., „Standardlastprofile Strom,” Bundesverband der Energie- und Wasserwirtschaft, 1999. [Online], Available: <https://www.bdew.de/energie/standardlastprofile-strom/>. [Zugriff: 09.01.2024].
- [20] L. Lisha und K. Jamieson, „Hyperband: A novel bandit-based approach to hyperparameter optimization,” *Journal of Machine Learning Research*, 18, S. 1-52, 2018.
- [21] J. Dean und R. Monga, „Large-scale machine learning on heterogeneous distributed systems,” *tensorflow.org*, 2015.
- [22] I. Goodfellow et al., „Generative adversarial nets,” *Advances in neural information processing systems*, 27, 2014.
- [23] T. Hastie et al., *The elements of statistical learning: Data mining, inference, and prediction*, New York: Springer, 2017.
- [24] Bundesnetzagentur, „Festlegung zur Durchführung der netzorientierten Steuerung von steuerbaren Verbrauchseinrichtungen und steuerbaren Netzanschlüssen nach § 14a EnWG,” Beschlusskammer 6, BK6-22-300, 2023.
- [25] L. Fahrmeir et al., *Statistik: Der Weg zur Datenanalyse*. Heidelberg: Springer Spektrum, 2016.
- [26] Bayerische Staatsregierung, „Hightech Agenda Bayern,” *Bayerische Staatsregierung*, 2019. [Online]. Available: <https://www.bayern.de/hightech-agenda-bayern/> [Zugriff: 30.01.2024].

Appendix

I. Qualitätskontrolle der künstlich erzeugten Extremszenarien

Durch das in Abschnitt 4.2.1 beschriebene GAN werden künstliche Wirk- und Blindleistungsszenarien für alle Stationen aus dem Netzabschnitt generiert. Die generierten Szenarien werden anhand von drei Bewertungskriterien beurteilt. Diese werden nachfolgend für die Szenarien mit hoher Wirkleistungssumme (Abbildung 18) und für die Szenarien mit niedriger Wirkleistungssumme (Abbildung 19) dargestellt. Zum einen werden die Wertebereiche der generierten Daten mit denen der realen verglichen. Zum anderen werden die paarweisen Korrelationen der einzelnen Messreihen verglichen, um zu prüfen, ob in den generierten Szenarien ähnliche Zusammenhänge vorliegen wie in den Realdaten. Optimalerweise sollten die Korrelationen identisch sein und somit auf der in Rot eingezeichneten Linie liegen. Zum Schluss wird eine zweidimensionale Einbettung der Szenarien durch eine Principle Component Analyse generiert, die verdeutlicht, ob die künstlichen Daten den realen in ihrer Grundverteilung ähneln. Es zeigt sich in beiden Fällen, dass die Wertebereiche der Szenarien vom GAN gut getroffen werden. Auch die zweidimensionale Einbettung der künstlichen Szenarien weist eine hohe Ähnlichkeit zur Einbettung der realen Szenarien auf. Hinsichtlich der Korrelationskoeffizienten zeigt sich das die realen Korrelationen in ihrer Tendenz gut abgebildet werden, die künstlichen Szenarien zu Zeiten geringer Gesamtlast weisen an dieser Stelle jedoch einige größere Abweichungen auf.

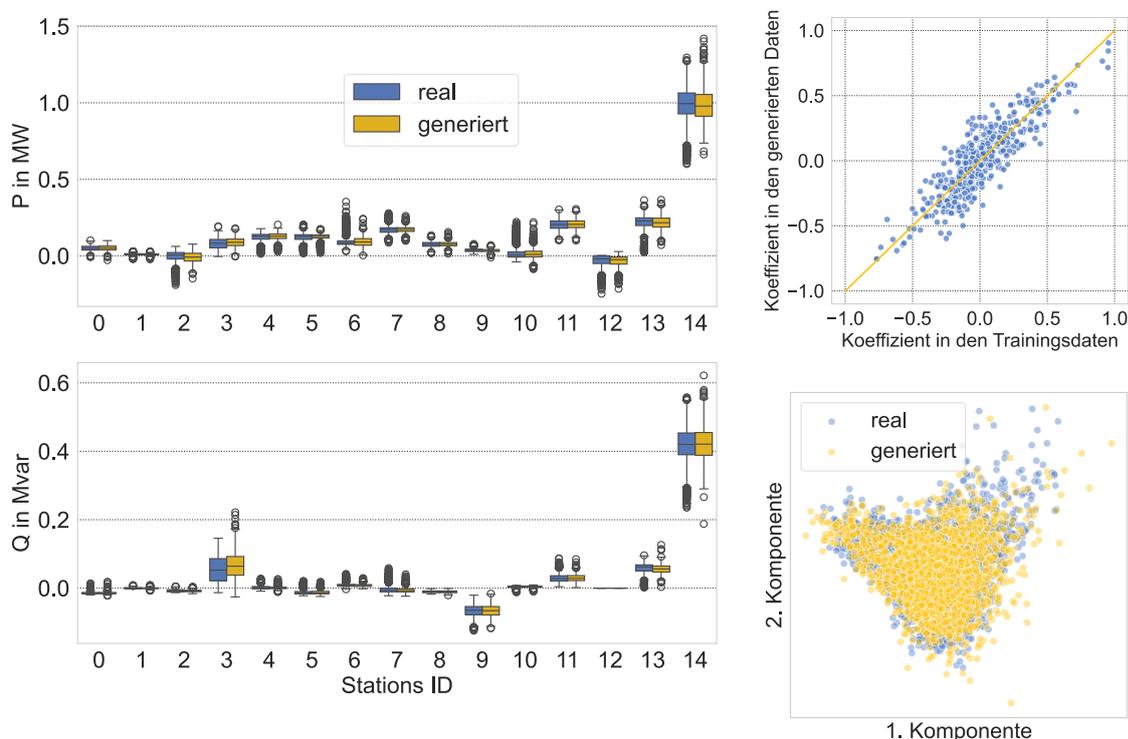


Abbildung 18: Qualitätskontrolle der generierten Szenarien zu Zeiten mit hoher Wirkleistungssumme. Linke Spalte: Wertebereiche der generierten Szenarien im Vergleich zu den realen Szenarien für Wirkleistung (oben) und Blindleistung (unten). Oben rechts: Paarweise Korrelationskoeffizienten der generierten Szenarien im Vergleich zu denen der realen Szenarien. Unten rechts: Zweidimensionale Einbettung der generierten und Realen Daten durch eine Principle Component Analyse.

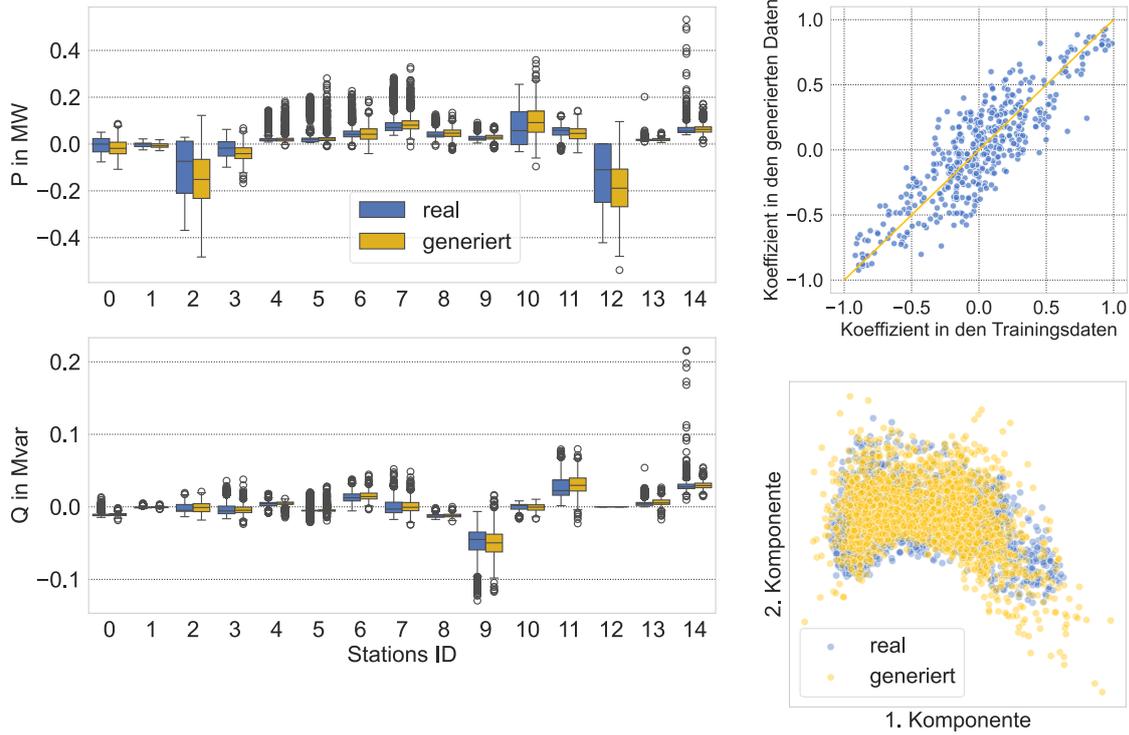


Abbildung 19: Qualitätskontrolle der generierten Szenarien zu Zeiten mit niedriger Wirkleistungssumme. Linke Spalte: Wertebereiche der generierten Szenarien im Vergleich zu den realen Szenarien für Wirkleistung (oben) und Blindleistung (unten). Oben rechts: Paarweise Korrelationskoeffizienten der generierten Szenarien im Vergleich zu denen der realen Szenarien. Unten rechts: Zweidimensionale Einbettung der generierten und Realen Daten durch eine Principle Component Analyse.