

# DAY-AHEAD NETZZUSTANDSPROGNOSE AUF MITTELSPANNUNGS- EBENE MIT NEURONALEN NETZEN

Sebastian STORCH<sup>1(\*)</sup>, Michael FINKEL<sup>1</sup>, Martin UHRIG<sup>2</sup>, Michael KREISSL<sup>3</sup>, Lothar BEHRINGER<sup>4</sup>

## Motivation und Inhalt

Die Energie-, Verkehrs- und Wärmewende stellen die elektrischen Energieversorgungsnetze vor große Herausforderungen. Durch eine hohe Anzahl dezentraler Erzeugungsanlagen und eine steigende Zahl elektrischer Verbraucher verändern sich die Netzeinspeisungen und -bezüge erheblich. Hierdurch ist im Mittel- und Niederspannungsnetz mit Engpässen zu rechnen. Zeitgleich liefern Modelle der Künstlichen Intelligenz (KI) aufgrund effizienterer Trainingsalgorithmen und neuer Anwendungsverfahren immer beeindruckendere Ergebnisse. Es liegt nahe, die Herausforderungen im Verteilnetz mit dem Potenzial der KI zu bewältigen [1]. Eine konkrete Anwendung ist eine Day-Ahead Zustandsprognose des Mittelspannungsnetzes mit Hilfe von Neuronalen Netzen. Eine derartige Prognose liefert Auskunft über Flexibilitäten im Netz, auf deren Basis Schalt- und Redispatchmaßnahmen gesteuert werden können. Eine Sensitivitätsanalyse des Verfahrens liefert zudem Aufschluss darüber, welchen Einfluss Messgeräte an den Netzstationen haben. Hieraus ergeben sich Asset-strategisch relevante Schlüsse darauf, an welchen und an wie vielen Stationen Messgeräte angebracht werden sollten, um ein Kosten-Nutzen-optimales Prognoseergebnis zu erhalten.

## Methodik

Der Netzzustand setzt sich aus den Leitungsauslastungen und den Knotenspannungen zusammen. Dieser wird auf Basis der verfügbaren Daten eines Tages für den Folgetag prognostiziert. Die Vorhersage wird durch die Verknüpfung von zwei neuronalen Netzen realisiert. Die Prognose wird für einen Mittelspannungsabschnitt ermittelt, der aus den Knotenpunkten  $v_1, \dots, v_n$  und den Leitungen  $e_1, \dots, e_m$  besteht. Die Knoten  $v_1, \dots, v_k$  mit  $k \leq n$  seien mit Messgeräten ausgestattet. Ziel ist es, auf Basis der aktuellen Messwerte an diesen Knoten die Knotenspannungen und Leitungsauslastungen im gesamten Netzabschnitt für den Folgetag zu prognostizieren. Dies geschieht in zwei Einzelschritten, die jeweils von einem neuronalen Netz ausgeführt werden (Abbildung 1). Zunächst werden die Messwerte an den Punkten  $v_1, \dots, v_k$  für den nächsten Tag in Abhängigkeit der aktuellen Messungen, der Wettervorhersage und Kalenderinformationen (Werktag, Samstag, Feiertag) vorhergesagt. Dies erfolgt durch ein autoregressives neuronales Netz mit zwei Long-Short-Term-Memory-Schichten und einer vollständigen Schicht (Modell 1). Auf Grundlage dieser Prognose bestimmt ein neuronales Feed-Forward-Netz (Modell 2) die Knotenspannungen und Leitungsauslastungen im gesamten Netzabschnitt. Die Trainingsdaten für die Entwicklung von Modell 1 sind durch die Messdaten an  $v_1, \dots, v_k$  gegeben. Zur Erzeugung von Trainingsdaten für Modell 2 werden Netzberechnungen durchgeführt, wobei durch das Anlegen von Wirk- und Blindleistung an den Knotenpunkten  $v_1, \dots, v_n$  die Knotenspannungen und prozentualen Leitungsauslastungen ermittelt

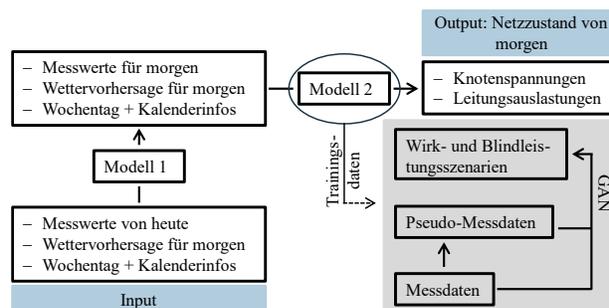


Abbildung 1: Schematisches Vorgehen bei der Netzzustandsprognose für den Folgetag.

Das Diagramm zeigt den Datenfluss von der Eingangsphase über zwei Modelle bis zum Output. Die Eingangsphase (Input) liefert Messwerte von heute, Wettervorhersage für morgen und Wochentag + Kalenderinfos an Modell 1. Modell 1 liefert Messwerte für morgen, Wettervorhersage für morgen und Wochentag + Kalenderinfos an Modell 2. Modell 2 liefert den Output: Netzzustand von morgen (Knotenspannungen, Leitungsauslastungen). Ein separater Prozess (GAN) generiert Trainingsdaten aus Messdaten über Pseudo-Messdaten und Wirk- und Blindleistungsszenarien, die in Modell 1 fließen.

<sup>1</sup> TH Augsburg, An der Hochschule 1, 86161 Augsburg (DE), +49 821 5586 3095, sebastian.storch@hs-augsburg.de, [www.tha.de](http://www.tha.de)

<sup>2</sup> LEW Verteilnetz GmbH, Schaezlerstraße 3, 86150 Augsburg (DE), [www.lew-verteilnetz.de](http://www.lew-verteilnetz.de)

<sup>3</sup> SWM Infrastruktur GmbH & Co. KG, Emmy-Noether-Straße 2, 80992 München (DE), [www.swm.de](http://www.swm.de)

<sup>4</sup> Stadtwerke Neuburg a. d. Donau, Heinrichsheimstraße 2, 86633 Neuburg a. d. Donau (DE), [www.stadtwerke-neuburg.de](http://www.stadtwerke-neuburg.de)

werden. Für die Sammelschienen mit Messgeräten  $v_1, \dots, v_k$  ist die Wirk- und Blindleistung bekannt, an den übrigen Knoten wird eine Annahme durch Pseudomesswerte basierend auf Standardlastprofilen getroffen. Liegt der Input für die Netzberechnung mithilfe der Mess- und Pseudo-Messdaten vor, wird dieser durch ein Generatives Adversariales Netz (GAN) erweitert. Dies erhöht die Anzahl der Szenarien bei der Zustandsermittlung und macht die Schätzung stabiler.

Während die einzelnen Modelle (Modell 1, Modell 2, GAN) in der Literatur bereits thematisiert wurden, zeichnet sich dieser Ansatz durch die Verknüpfung der Modelle unter Verwendung realer Netz- und Messdaten aus. Dies ermöglicht eine konkrete Bestimmung der Gesamtabweichung der verketteten Modelle.

## Ergebnisse

Die Ergebnisse beziehen sich auf einen Mittelspannungsabschnitt eines kleinstädtischen Verteilnetzbetreibers mit 14 Netzstationen. Auch Industriebetriebe und ein großer PV-Park sind angeschlossen. An allen Stationen waren im Jahr 2022 Messgeräte installiert, die Wirk- und Blindleistung in 15-minütiger Auflösung gemessen haben. Diese Daten dienen als Trainingsdaten für die Modelle.

### Basismodell

Unter der Annahme, dass alle Messwerte bekannt sind und im Netzbetrieb live ausgelesen werden können, weisen die Prognosen des Netzzustands geringe Abweichungen vom Ist-Wert auf. Die über die Leitungsmenge gemittelten Abweichungen der Prognose vom Ist-Wert an einer Testmenge von Tagen, die im Training nicht einbezogen wurde, sind in Abbildung 2 zu sehen.

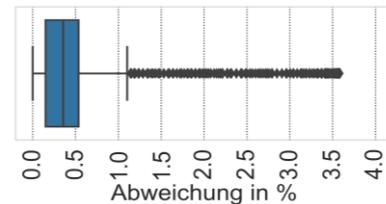


Abbildung 2: Gemittelte absolute Abweichungen der Leitungsauslastungsprognose vom tatsächlichen Wert.

### Lastspitzenbehandlung

Insbesondere bei Last- und Einspeisespitzen neigen die Modelle 1 und 2 dazu, den tatsächlichen Wert zu unterschätzen. Da diese Extremszenarien wegen möglicher Grenzwertverletzungen von hoher Relevanz sind, wurden zwei Verfahren implementiert, die es erlauben, diese Extrema zu berücksichtigen. Durch eine Kerndichteschätzung der Abweichungen von Modell 1 werden Intervalle berechnet, die den Bereich angeben, in dem der tatsächliche Wert am wahrscheinlichsten liegt (Abbildung 3). Der Übergang zum 5 %-Perzentil-Intervall führt dazu, dass die Unterschätzung von Extrema durch Modell 1 beseitigt wird. Auf der anderen Seite wird die Menge der extremen Last- und Einspeiseszenarien in den Trainingsdaten von Modell 2 mithilfe eines GAN künstlich vervielfältigt. Durch eine höhere Gewichtung der Extremszenarien in den Trainingsdaten, verschwindet die Unterschätzung von Auslastungsspitzen in Modell 2.

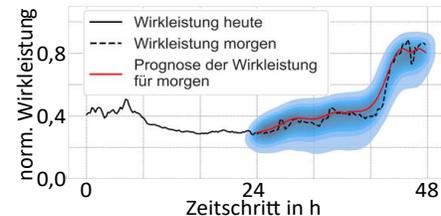


Abbildung 3: Wirkleistungsprognose mit Abweichungsverteilung

### Sensitivitätsanalyse

Da auf Mittelspannungsnetzebene in der Regel keine vollständige Durchdringung mit Messgeräten besteht, wird außerdem untersucht, wie die Qualität der Netzzustandsprognose abnimmt, wenn anstelle realer Messwerte nur Pseudo-Messwerte verwendet werden. Dabei zeigt sich, dass sich der Prognosefehler bei ausschließlicher Verwendung von Pseudomesswerten gegenüber dem Basismodell verdoppelt. Zudem wird ein Verfahren aufgezeigt, mit dem festgelegt werden kann, welche und wie viele Stationen mit Messgeräten ausgestattet werden müssen, um eine gewünschte Genauigkeit zu erzielen.

## Referenzen

- [1] M. Klobasa, P. Plötz, S. Pelka und L. Vogel, „Künstliche Intelligenz für die Integrierte Energiewende,“ Fraunhofer-Institut für System- und Innovationsforschung ISI, Karlsruhe, Dez. 2019.