

Maschinelles Lernen in der Niederspannung: Wie Modelle auf Basis von Messwerten die Prozesse im Verteilnetz unterstützen

Manuel Treutlein, Marc Schmidt, Sven Zahorka, Felix Kraus, Ralf Mikut und Veit Hagenmeyer

Im Rahmen der Energiewende stehen die Verteilnetzbetreiber (VNBs) vor erheblichen Herausforderungen in ihren Niederspannungsnetzen, sowohl im Betrieb als auch in der Planung. Mit Maschinellen Lernen erzeugte Modelle bieten dem VNB das Potenzial, basierend auf netzeigenen Daten bestehende Prozesse datengetrieben weiterzuentwickeln und neuen Anforderungen gerecht zu werden. Im Folgenden wird ein Framework vorgestellt, welches auf Basis verschiedener Modelle und Datengrundlagen Leistungsschätzungen für Netzbetriebsmittel ermöglicht. Darüber hinaus wird auf ein Modell zur Extremwertschätzung und ein Modell zur Erzeugung von Pseudomessdaten näher eingegangen.

Umbruch in den Niederspannungsnetzen

Zahlreiche Studien weisen auf den enormen Planungs- und Ausbaubedarf der Niederspannungsnetze für die erfolgreiche Integration von Photovoltaikanlagen, Elektroautos und Wärmepumpen im Zuge der Energiewende hin [1, 2]. Neue gesetzliche Regelungen wie der 2023 novellierte §14a EnWG zum Steuern von Verbrauchseinrichtungen in der Niederspannung verdeutlichen darüber hinaus die Herausforderungen im Betrieb [3]. Diese Entwicklungen erfordern bei den VNBs eine erhöhte Transparenz über den Leistungsbedarf und die Auslastung in den Niederspannungsnetzen. Aus diesem Grund statten die VNBs ihre Transformatoren und Niederspannungsabgänge kontinuierlich mit mehr Messgeräten aus [4]. Für die VNBs stellt sich die Frage, wie diese Messungen möglichst schnell und einfach in die bestehenden Prozesse integriert werden können, um diese zu verbessern und Kosten einzusparen. Neben der direkten Analyse und Nutzung der Messwerte bieten die Fortschritte im Bereich des Maschinellen Lernens großes Potential, um mit Modellen auf Basis weniger Messwerte einen Werthebel für das gesamte Netzgebiet zu schaffen.

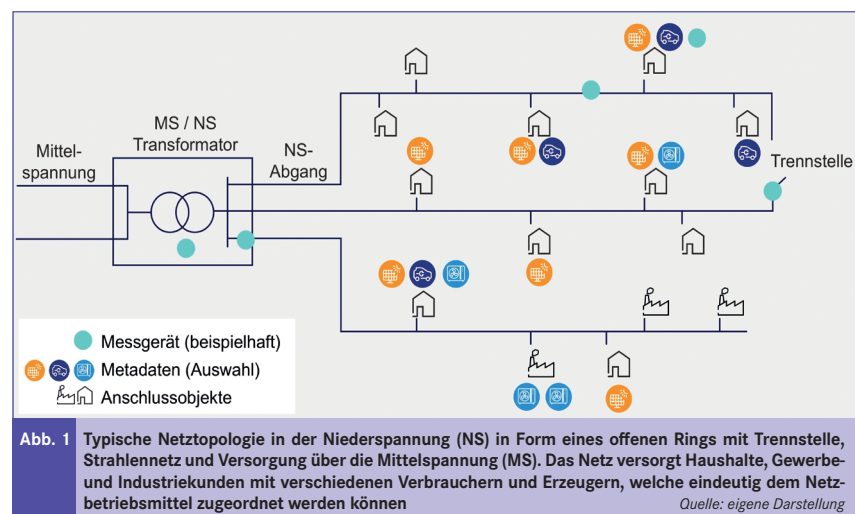
Neben der daten- und modellgetriebenen Verbesserung von etablierten Prozessen wie der Erfassung von Maximalströmen (Schleppzeiger), Gleichzeitigkeitsfaktoren oder Standardlastprofilen können auch neu entstehende, zeitreihenbasierte Prozesse entwickelt und unterstützt werden. Dies umfasst beispielsweise Zeitreihen-

vorhersagen, Zustandsschätzungen (State Estimation) oder zeitreihenbasierte Lastflussrechnungen. Eine essenzielle Voraussetzung für das Training von Modellen ist die Verknüpfung der Messwerte aus dem Niederspannungsnetz mit weiteren Datenquellen, wie Wetterdaten, Kalenderdaten (Zeitinformationen) oder Metadaten, zu den angeschlossenen Verbrauchern und Erzeugern. Dies kann auf Basis von Datenplattformen und digitalen Zwillingen realisiert werden [5].

Die typische Netztopologie in deutschen Niederspannungsnetzen entspricht einem offen oder geschlossen betriebenen Ring oder einem Strahlennetz (Abb. 1). Nur vereinzelt werden auch vermaschte Netze in der Niederspannung betrieben [6]. Somit können Metadaten meist eindeutig dem Niederspannungsabgang und dem Transformator zugeordnet werden. Unter Metadaten fallen angemeldete Netzanlassknoten wie Haushalte, Gewerbe und kleine Industriebetriebe sowie an-

gemeldete Leistungen zu Einspeisern und Verbrauchern wie Photovoltaikanlagen, Wärmepumpen oder Ladestationen für Elektroautos. Die Aufzeichnung von Messdaten ist bei Netzbetriebsmitteln wie Transformatoren, Niederspannungsabgängen oder Kabelverteilerschränken möglich. Viele VNBs haben jedoch nur in einem Teil ihrer Niederspannungsnetze Messgeräte an den Netzbetriebsmitteln verbaut. Smartmeter-Messdaten und registrierende Leistungsmessungen (RLM), welche dem VNB auf der Ebene von Haushalten und Gewerben Messwerte zur Verfügung stellen könnten, sind häufig nicht verfügbar. Darüber hinaus stellt sich die Frage, welche Metadaten zu welchem Leistungsbedarf an den Betriebsmitteln führen, beispielsweise um den zukünftigen Leistungsbedarf bei mehr Erzeugern und Verbrauchern zu prognostizieren.

Im nachfolgend eingeführten Framework werden die Metadaten aus dem Netz zu-



sammen mit weiteren Merkmalen verwendet, um die aktuelle und zukünftige Leistung bei Netzbetriebsmitteln zu schätzen. Auf zwei Modelle aus dem Framework zur Schätzung der Spitzenlast (Extremwertmodell) und zur Erzeugung von Pseudomesswerten wird genauer eingegangen. Mit den vorgestellten Modellen können VNBs ihren Datenbestand aus Teilmessungen nutzen, um Leistungsschätzungen schnell auf ihr Gesamtnetz zu skalieren.

Framework zur Leistungsschätzung

Das eingesetzte Framework visualisiert Netzbetriebsmittel, Modellvariation und notwendige Datengrundlage (Abb. 2). Zunächst sind mit dem Transformator, dem Niederspannungsabgang sowie dem Kabelverteilerschrank drei verschiedene Netzbetriebsmittel bzw. Stellen im Netz aufgeführt, für welche eine Modellschätzung erfolgen kann. Als Modellvariationen sind *Extremwerte*, *Last- und Erzeugungsprofil*, *Pseudomesswerte* sowie eine *Zeitreihenvorhersage* aufgeführt. Für alle Modelle kommt zur Erzeugung Maschinelles Lernen zum Einsatz. Je nach Modellvariante wird eine unterschiedliche Datengrundlage benötigt. Die Datengrundlage unterscheidet sich ebenfalls danach, ob das Modell erzeugt (Training) oder ein vorhandenes Modell angewandt wird (Inferenz).

Messdaten, z.B. zur Wirkleistung an einem Niederspannungsabgang, sind als vorherzusagende Zielvariable Voraussetzung für jedes Modelltraining. In der Inferenz werden jedoch nur für das Modell der Zeitreihenvorhersage Messdaten vom zu prognostizierenden Netzbetriebsmittel benötigt. Während das Modell zur Zeitreihenvorhersage die Grundlast sowie Leistungskurve durch die historischen Messdaten erlernen kann, benötigen die anderen drei Modelle weitere Metadaten. Dies können z.B. die angemeldeten Erzeuger und Verbraucher im Niederspannungsnetz sein. Das Extremwerte-Modell prognostiziert eine höchste Auslastung ohne zeitliche Auflösung nur auf Basis solcher Metadaten. Die Modelle für Profile sowie für Pseudomesswerte benötigen hingegen noch zeitliche Informationen, sodass die Modelle als Ausgabe Tages- und Wochenprofile bzw. voll-

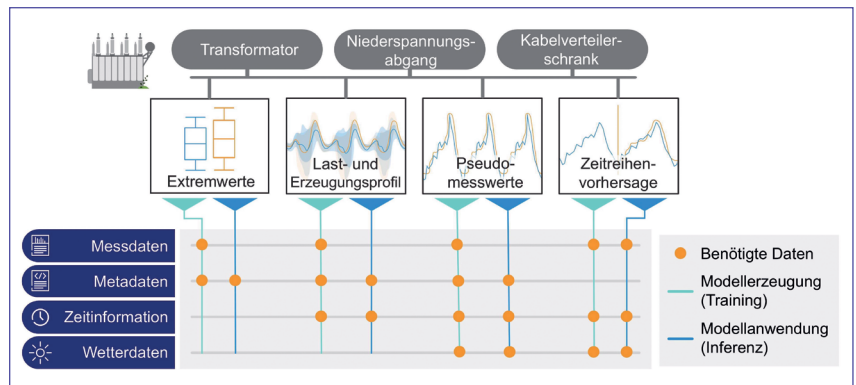


Abb. 2 Framework zur Leistungsschätzung an Netzbetriebsmitteln in der Niederspannung. Die Modelle unterscheiden sich nach dem Ausgabeformat und der notwendigen Datengrundlage

Quelle: eigene Darstellung

ständige Zeitreihen prognostizieren können. Aufgrund der stark wetterabhängigen Erzeugung durch Photovoltaikanlagen und wetterabhängiger Heizlast sind Wetterdaten, inklusive Wetterprognosen, weitere wichtige Indikatoren für die zeitreihenbasierten Modelle Pseudomesswerte und Zeitreihenvorhersage.

Bei der Auswahl der Modelle ist zu beachten, dass der Leistungsverlauf bei geringer Anzahl an Anschlussobjekten volatil ist [7]. Je nach Anwendung kann es deswegen sinnvoll sein, probabilistische Modelle anstelle von Punktschätzmodellen zu verwenden, um die Unsicherheit der Prognose zu berücksichtigen. Bei zu geringer Datenmenge kann die Augmentierung der Daten durch Aufsummieren der Messzeitreihen mehrerer Netzbetriebsmittel hilfreich sein. Neben der Schätzung von Leistungen können die Modelle ebenfalls verwendet werden, um Ströme und Spannungen in unvermaschten Netzen zu schätzen.

Leistungsschätzungen für Bestandsprozesse

Zur Planung und Betrieb des Verteilnetzes haben sich Verfahren wie *Schleppzeiger* [8] und *Gleichzeitigkeitsfaktoren* [9] etabliert. Der Schleppzeiger gibt für einen Transformator den höchsten aufgetretenen Strom seit der letzten Zurücksetzung an. Ein Extremwertmodell auf Basis von Messdaten und Metadaten (siehe Abb. 2) kann den Prozess *Schleppzeiger ablesen* ersetzen, indem die maximale Last oder die maximale Einspeisung am Transformator geschätzt wird. Darüber hinaus ermöglicht ein Extremwertmodell, kombinierte Gleichzeitigkeitsfaktoren anhand der VNB-eigenen Netze zu ermitteln. Dazu können im Modell beispielsweise die Merkmale *Wallbox*, *Photovoltaikanlage* und *Wärmepumpe* schrittweise beliebig erhöht werden. Dies würde einen Hochlauf von Verbrauchern und Erzeugern im Zuge der Energiewende darstellen.

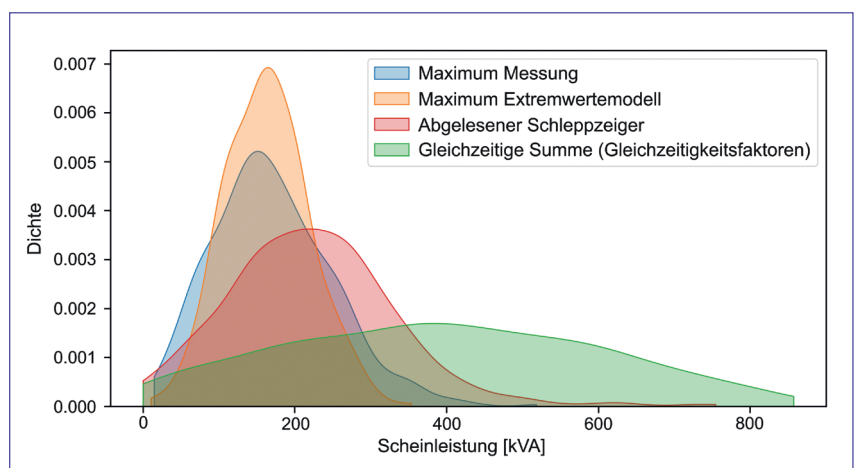


Abb. 3 Wahrscheinlichkeitsdichtefunktion der Scheinleistung für 510 Transformatoren mit unterschiedlichen Methoden. Die Methode „Maximum Extremwertmodell“ basiert auf den Messdaten und enthält in der Abbildung auch die Trainingsdaten

Quelle: eigene Darstellung

Zum Vergleich unterschiedlicher Methoden zur Messung und Schätzung der maximal auftretenden Scheinleistung am Transformator sind die Dichtefunktionen basierend auf 510 Transformatoren im Netze BW Gebiet dargestellt (Abb. 3). Die Methoden umfassen das *Maximum der Messung*, das *Maximum des Extremwertmodells*, die Verbrauchssumme der angemeldeten Metadaten über eine *Gleichzeitigkeitstabelle* sowie den *abgelesenen Schleppzeiger* aus dem analogen Prozess. Alle Transformatoren sind mindestens ein Jahr gemessen und der Maximalstrom ist bedingt durch den jeweiligen Verbrauch. Die Dichtefunktion des Maximums der Messzeitreihe und des Maximums des Modells ist ähnlich zueinander, allerdings ist beim Maximum der Messzeitreihe mehr Masse in den Verteilungsenden. Dies könnte an den Ausreißern in den Messdaten liegen sowie daran, dass ein Modell mit quadratischer Verlustfunktion die mittlere quadratische Abweichung zu allen Transformatoren-Maxima optimiert.

Die Dichtefunktion des abgelesenen Schleppzeigers ist im Vergleich zum Maximum der Messung und dem Modell nach rechts verschoben. Das heißt, die Leistungswerte beim abgelesenen Schleppzeiger sind durchschnittlich höher. Dies kann an den längeren Ableseintervallen des Schleppzeigers im Vergleich zu den Messzeitreihen liegen, welche lediglich

mindestens ein Jahr Messdaten haben müssen. Bei der Dichtefunktion zu den Gleichzeitigkeitsfaktoren wird deutlich, dass diese im Vergleich zu den anderen drei Methoden eine deutliche Worst-Case-Abschätzung darstellen. Die hier berechnete gleichzeitige Summe für Transformatoren berücksichtigt lediglich die Verbraucher im darunterliegenden Netz. Bei Berücksichtigung von Wohneinheiten liegt die gleichzeitige Summe noch höher.

Die Dichtefunktionen in Abb. 3 machen keine Aussage über die Performance des Extremwerte-Modells in Bezug auf das Maximum, da bei den 510 Transformatoren auch jene aus dem Trainingsdatensatz enthalten sowie keine Fehler zwischen individuellen Transformator-Schätzungen dargestellt sind. Eine fünffache Kreuzvalidierung mit 1.172 Transformatoren ergibt für den Testdatensatz mit einem XGBoost-Modell einen durchschnittlichen absoluten Fehler von 26,4 kVA bei einer Standardabweichung von 1,6 kVA.

Das Framework (siehe Abb. 2) ermöglicht ebenfalls, Last- und Erzeugungsprofile an Netzbetriebsmitteln zu erzeugen. Damit können Prozesse verbessert werden, welche auf *Standardlastprofilen* basieren [10]. Dazu werden aus den Messdaten für verschiedene Saisonalitäten durchschnittliche Tages- oder Wochenprofile erzeugt und als Zielvariab-

len verwendet. Als Modellmerkmal werden neben den Metadaten noch Informationen zum Zeitpunkt, zum Beispiel die Stunde der Woche bei einem Wochenprofil, verwendet. Ein ähnlicher Ansatz aus dem Bereich Transfer Learning ist in [11] beschrieben.

Leistungsschätzungen für neue Prozesse

Neue Anforderungen an VNBs, wie das Steuern von Verbrauchseinrichtungen nach der Novellierung des § 14a EnWG im Jahr 2023, erfordern zeitreihenscharfe Informationen über die Auslastung der Niederspannungsnetze. Idealerweise sind dazu Messwerte an den Netzbetriebsmitteln vorhanden, welche als Modellmerkmal für eine Zeitreihenvorhersage genutzt werden können [7] (siehe Abb. 2). Des Weiteren können als Modellmerkmale erneut Metadaten sowie eine geeignete Kodierung für den Zeitpunkt eingesetzt werden. Wetterdaten, z.B. die Temperatur oder Globalstrahlung, verbessern die Schätzung aufgrund von wetterabhängiger Erzeugung und Verbrauch.

Allerdings sind Messgeräte an vielen Netzbetriebsmitteln nicht verbaut, wodurch kein klassisches Zeitreihenvorhersagemodell anwendbar ist. Ein Pseudomesswerte-Modell kann die Messzeitreihe auch ohne historische Werte in

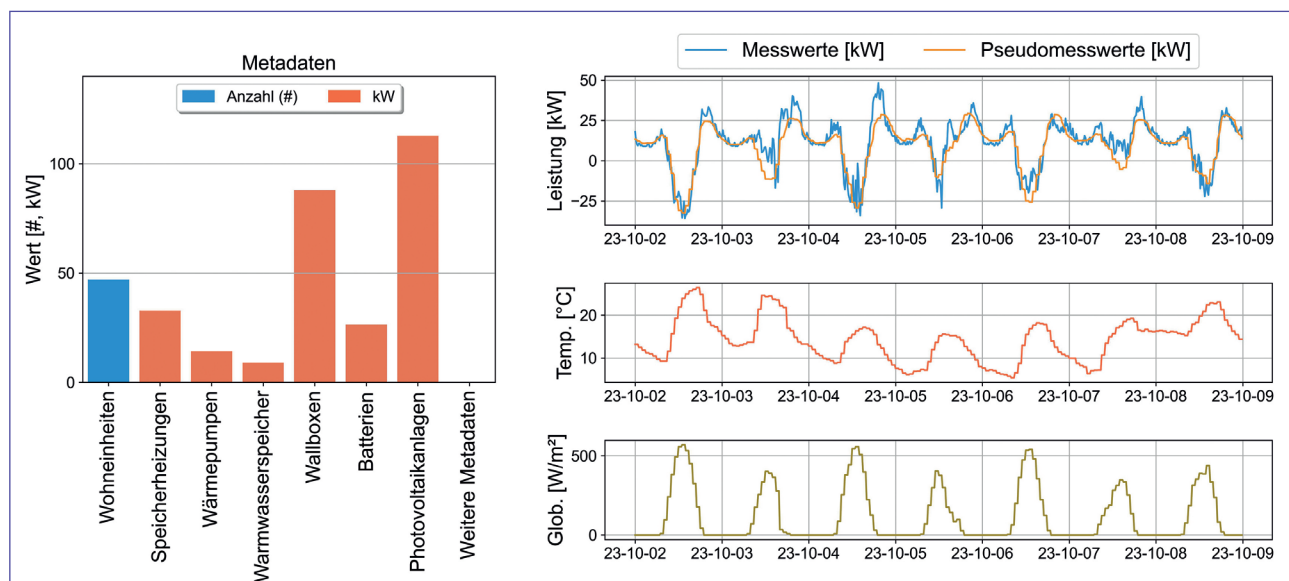


Abb. 4 Metadaten, Temperatur, Globalstrahlung, Messdaten (blau) und Schätzung (orange) eines ausgewählten Niederspannungsabgangs für das Pseudomesswerte-Modell in 15-minütiger Auflösung der Wirkleistung für die Woche vom 2. bis 8. Oktober 2023

Quelle: eigene Darstellung

Form von Pseudomesswerten schätzen (siehe Abb. 2). Basierend auf der Publikation [12] werden Pseudomesswerte zusammen mit der tatsächlichen Messung, Metadaten und Wetterdaten gezeigt (Abb. 4). Für die ausgewählte Woche im Oktober zeigt die Messzeitreihe für einen Niederspannungsabgang eine Netto-Einspeisung zu Zeiten mit hoher Globalstrahlung. Außerdem ist erkennbar, dass die Lastspitzen in den Abendstunden stärker ausgeprägt sind als am Morgen. Dieses Lastverhalten findet sich auch in den Pseudomessdaten wieder.

Herausforderungen bei der Erzeugung von Pseudomessdaten stellen insbesondere Leistungsspitzen dar. In [12] wird analysiert, dass der durchschnittliche absolute Fehler über alle Messdaten mit 4,73 kW deutlich niedriger liegt als der absolute durchschnittliche Fehler für Last- oder Einspeisespitzen mit 11,66 kW und 13,13 kW. Bei dem gezeigten Niederspannungsabgang könnte die Lastspitze am Abend des 4. Oktobers 2023 z.B. durch die angemeldeten Speicherheizungen oder Wallboxen hervorgerufen werden. Verbesserungen könnten durch eine Verlustfunktionen mit stärkerem Fokus auf Spitzenwerte oder probabilistische Modelle zur Schätzung der Unsicherheit erreicht werden. Darüber hinaus gilt, wie für alle Modelle in Abb. 2, dass eine gute Datenqualität sowie aussagekräftige und repräsentative Modellmerkmale essenziell sind.

Fazit

Basierend auf dem Framework zeigen die vorherigen Abschnitte verschiedene Modelle auf, um Bestandsprozesse sowie neue Prozesse bei VNBs daten- und modellgetrieben zu verbessern (siehe Abb. 2). Dies reicht von einfachen Prozessen wie dem Ablesen des Schleppzeigers bis hin zur Unterstützung beim Aufbau neuer Fähigkeiten im Verteilnetz wie dem Steuern in der Niederspannung. Die Modelle basieren dabei auf einem Datenpool, welcher Mess-, Meta-, Kalender- und Wetterdaten gewinnbringend miteinander verknüpft. Der resultierende Mix aus Modellschätzungen und tatsächlichen Messwerten ermöglicht so dem VNB effizientere Bestandsprozesse und die Transparenz für aktuelle und zukünftige Anforderungen im Verteilnetz.

Literatur

- [1] Gust G., Schlüter A., Feuerriegel S., Úbeda I., Lee J. T., Neumann D.: Designing electricity distribution networks: The impact of demand coincidence. *European Journal of Operational Research*, vol. 315, no. 1, pp. 271–288, 2024, doi: 10.1016/j.ejor.2023.11.029
- [2] Cakmak H. K., Hagenmeyer V.: Using Open Data for Modeling and Simulation of the All Electrical Society in eASiMOV. *Open Source Modelling and Simulation of Energy Systems (OSMSES)*, Aachen, Germany: IEEE, 2022, pp. 1–6. doi: 10.1109/OSMSES54027.2022.9769145
- [3] Bundesnetzagentur: Festlegung zur Durchführung der netzorientierten Steuerung von steuerbaren Verbrauchseinrichtungen und steuerbaren Netzanschlüssen nach § 14a EnWG. vol. BK6-22–300. Bonn 2023. Verfügbar unter: https://www.bundesnetzagentur.de/DE/Beschlusskammern/1_GZ/BK6-GZ/2022/BK6-22-300/BK6-22-300_Beschluss.html?nn=993170 (abgerufen am 10.02.2025).
- [4] Bundesnetzagentur: Bericht Zustand und Ausbau der Verteilernetze 2022. Bonn 2023. Verfügbar unter: https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Sachgebiete/Energie/Unternehmen_Institutionen/NetzentwicklungUndSmartGrid/ZustandAusbauVerteilernetze2022.pdf?__blob=publicationFile&v=2 (abgerufen am 10.02.2025).
- [5] Böttcher, A.: Professionelles Datenmanagement in Form eines digitalen Zwillings. Offenbach am Main 2024. Verfügbar unter: <https://emagazin.ew-magazin.de/de/profiles/a21024e15cd4/editions/e247bfbdbbe6edd3e6b5/pages/page/27> (abgerufen am 10.02.2025).
- [6] Heuck K., Dettmann K.-D., Schulz D.: Elektrische Energieversorgung: Erzeugung, Übertragung und Verteilung elektrischer Energie für Studium und Praxis. Wiesbaden: Springer Fachmedien Wiesbaden, 2013. doi: 10.1007/978-3-8348-2174-4
- [7] Haben S., Voss M., Holderbaum W.: Core Concepts and Methods in Load Forecasting: With Applications in Distribution Networks. Cham: Springer International Publishing, 2023. doi: 10.1007/978-3-031-27852-5
- [8] Schwab A. J., Elektroenergiesysteme: Smarte Stromversorgung im Zeitalter der Energiewende. Berlin, Heidelberg: Springer Berlin Heidelberg, 2022. doi: 10.1007/978-3-662-64774-5
- [9] VDE FNN: Ermittlung von Gleichzeitigkeitsfaktoren für Ladevorgänge an privaten Ladepunkten. Berlin 2021. Verfügbar unter: <https://www.vde.com/resource/blob/2093290/f88d9a470a0ac56f8dbba7e7a8136b8a/01-download-studie-gleichzeitigkeitsfaktoren-data.pdf> (abgerufen am 10.02.2025).
- [10] VDEW: Repräsentative VDEW-Lastprofile. Frankfurt am Main 1999. Verfügbar unter: <https://www.bdew.de/energie/standardlastprofile-strom/> (abgerufen am 10.02.2025).
- [11] Salazar M., Dukovska I., Nguyen P. H., Bernards R., H. J. G. Slootweg H. J. G.: Data Driven Framework for Load Profile Generation in Medium Voltage Networks via Transfer Learning. *IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*, The Hague, Netherlands: IEEE, 2020, pp. 909–913. doi: 10.1109/ISGT-Europe47291.2020.9248753
- [12] Treutlein M., Schmidt M., Hahn R., Hertel M., Heidrich B., Mikut R., Hagenmeyer V.: “Generating peak-aware pseudo-measurements for low-voltage feeders using metadata of distribution system operators”, *IET Smart Grid*. e12210 (2025). doi: <https://doi.org/10.1049/stg2.12210>

M. Treutlein, M. Schmidt, S. Zahorka, F. Kraus, Netze BW GmbH Stuttgart; M. Treutlein, R. Mikut, V. Hagenmeyer, Institut für Automation und angewandte Informatik (IAI) am Karlsruher Institut für Technologie (KIT) Karlsruhe
Kontakt:
manuel.treutlein@partner.kit.edu

Danksagung

Die Autoren danken der Netze BW GmbH, insbesondere allen Teammitgliedern des Projekts Niederspannungsprognose, für die für die Studien erforderlichen Daten und die Infrastruktur. Darüber hinaus möchten wir der Helmholtz-Gemeinschaft für die Unterstützung durch das Programm „Energy System Design“ und die Initiative Helmholtz AI danken. Herzlichen Dank an Heather Carson und Susanne Frank bei der grafischen Unterstützung.