

MONITORING IN DER MITTELSPANNUNGSEBENE MIT KÜNSTLICHEN NEURONALEN NETZEN – EINE VALIDIERUNG DER METHODIK AUF BASIS VON GEMESSENEN ORTSNETZSTATIONEN

Marcel DIPP¹, Jan-Hendrik MENKE¹, Sebastian WENDE - VON BERG², Andrea MAURUS³, Tobias KERBER⁴, Martin BRAUN^{1,2}

Diese Veröffentlichung basiert auf Erkenntnissen aus dem Forschungsprojekt Netzbetreiberübergreifendes Blindleistungsmanagement in Verteilnetzen (RPC2), welches durch das Bundesministerium für Wirtschaft und Energie gefördert wird. (Förderkennzeichen: 0350003C)

Gefördert durch:



aufgrund eines Beschlusses des Deutschen Bundestages

Motivation und Zielsetzung

Aufgrund der historisch gewachsenen Struktur existieren in der Mittelspannungsebene nur wenige Messeinrichtungen. In der Regel sind nur die HS/MS-Umspannstationen vollständig ausgemessen. Weitere Messungen finden sich vereinzelt an MS/NS-Ortsnetzstationen. Der aktuelle Zustand über sicherheitsrelevante Systemgrößen wie Leistungsstrom, Spannungsbetrag, Wirk- und Blindleistung ist mit Ausnahme der verfügbaren Messwerte unbekannt. Mit dem voranschreitenden Ausbau volatiler dezentraler Erzeugungsanlagen und dem variierenden Lastverhalten der Stromkunden, erhöht sich die Wahrscheinlichkeit für Grenzwertverletzungen innerhalb der Mittelspannungsebene [1]. Eine Detektion kritischer Netzzustände kann durch die geringe Anzahl an Messungen nicht gewährleistet werden. Der Zubau von Messeinrichtungen ist für den Netzbetreiber aufgrund der Kosten für die notwendige Kommunikations- und Messtechnik sowie Wartungs- und Personalkosten meist unwirtschaftlich. Um Sichtbarkeit und Transparenz in der Mittelspannungsebene zu erzeugen, arbeiten wir an einer Methodik, die elektrische Variablen im Stromnetz mittels künstlicher neuronaler Netze (KNN) schätzt [2]. In dieser Arbeit wird eine Validierung der Methodik vorgenommen, wobei im Forschungsprojekt RPC2 (Reactive Power Control 2) die elektrischen Variablen in realen Mittelspannungsnetzen der Verteilnetzbetreiber LEW Verteilnetz GmbH und AllgäuNetz geschätzt werden und anschließend ein Vergleich mittels gemessener Jahreszeitreihen von MS/NS-Ortsnetzstationen stattfindet.

Methodik

Die Trainingsdaten werden mit Leistungsflussberechnungen auf Basis von Zeitreihen eines Jahres und den zugehörigen Messdaten erstellt. Hierbei werden Einspeisezeitreihen für Wind, Biogas, Wasserkraft,




Abbildung 1: Mittelspannungsnetzgebiet (links) und Schema für den operativen Betrieb des Monitorings (rechts)

¹ Universität Kassel, Fachgebiet Energiemanagement und Betrieb elektrischer Netze, Wilhelmshöher Allee 71-73, D-34121 Kassel, +49 561 8046432, marcel.dipp@uni-kassel.de

² Abteilung Netzplanung und Netzbetrieb, Fraunhofer IEE, Königstor 59, D-34121 Kassel

³ Netzplanung/AllgäuNetz GmbH & Co. KG, Illerstraße 18, D-87435 Kempten

⁴ Assetmanagement HS/MS/LEW Verteilnetz GmbH, Schälzlerstraße 3, D-86150 Augsburg

und Photovoltaik berücksichtigt [3]. Standardlastprofile repräsentieren die verschiedenen Lasttypen. Die Lastzeitreihen werden zusätzlich durch gleichverteiltes Rauschen gewichtet, um individuelles Lastverhalten realistischer nachzubilden. Die Netzstruktur, sowie Platzierung, Typ, und Messrauschen werden in pandapower [4] abgebildet. Anschließend werden KNNs (Multilayer Perceptrons) mit geeigneten Sets an Hyperparametern in PyTorch [5] trainiert und somit in die Lage versetzt, Ausgangsvariablen als Approximationsfunktionen einer geringen Anzahl von Eingangswerten zu beschreiben. Für das Training der KNN werden nur die Messungen des HS/MS-Umspannwerks berücksichtigt. Im nächsten Schritt schätzen die trainierten KNNs anhand der wenigen Messwerte am HS/MS-Umspannwerk die elektrischen Variablen im gesamten Mittelspannungsnetz (Abbildung 1). Zuletzt erfolgt eine Auswertung der Schätzgenauigkeit durch den Vergleich mit den realen Messreihen der MS/NS-Ortnetzstationen.

Ergebnisse

Insgesamt wurden zwei verschiedene Netzgebiete für die Validierung herangezogen. Dabei zeigen die Ergebnisse der Simulationen, dass die KNN in der Lage sind, die elektrischen Zustandsgrößen adäquat zu schätzen. Abbildung 2 zeigt die Wirkleistungsschätzungen der KNN im Vergleich zu den realen Zeitreihen, der zwei Messeinrichtungen für P1 und P2 der MS/NS-Ortnetzstation (ONS) für das Netzgebiet aus Abbildung 1. Hierdurch wird gezeigt, dass KNNs in der Lage sind, elektrische Variablen auch während des operativen Betriebs zu schätzen. Dabei ist zu berücksichtigen, dass die Ortsnetzstationen nur einen Ausschnitt des gesamten Mittelspannungsnetzes repräsentieren.




Abbildung 2: Vergleich realer Messreihen der ONS (Exakter Wert P1 und P2) mit den Schätzergebnissen der KNN (Geschätzter Wert P1 und P2) im Zeitraum: 01.01.17-03.01.17

Referenzen

- [1] Deutsche-Energie-Agentur: dena Verteilnetzstudie. Ausbau- und Innovationsbedarf der Stromverteilnetze in Deutschland bis 2030, Dezember 2013.
- [2] J.-H. Menke, N. Bornhorst, and M. Braun: Distribution System Monitoring for Smart Power Grids with Distributed Generation Using Artificial Neural Networks, International Journal of Electrical Power & Energy Systems, Volume 113, December 2019, Pages 472-480.
- [3] M. Dipp, J.-H. Menke, S. Wende - von Berg, M. Braun, Training of Artificial Neural Networks Based on Feed-in Time Series of Photovoltaics and Wind Power for Active and Reactive Power Monitoring in Medium-Voltage Grids, INFORMATIK 2019, Bonn
- [4] Thurner, L.; Scheidler, A.; Schäfer, F.; Menke, Braun, M et al.: pandapower - An Open-Source Python Tool for Convenient Modeling, Analysis, and Optimization of Electric Power Systems. IEEE Transactions on Power Systems, 33(6):6510–6521, Nov 2018.
- [5] Paszke, Adam; Gross, Sam; et al., Automatic differentiation in PyTorch, NIPS-W, 2017.