

Zustandsschätzung der Spannungsqualität im Microgrid mithilfe eines digitalen Zwillings und neuronaler Netze

Markus de Koster¹, Patrick Mack², Patrick Lehnen³, Prof. Dr. Eberhard Waffenschmidt⁴, Prof. Dr. Ingo Stadler⁵

¹markus.de.koster@th-koeln.de

²patrick.mack@th-koeln.de

³patrick.lehnen@th-koeln.de

⁴eberhard.waffenschmidt@th-koeln.de

⁵ingo.stadler@th-koeln.de

*Technische Hochschule Köln
Cologne Institute for Renewable Energy
Betzdorfer Str. 2 50679 Köln*

Abstract

Methoden zur Schätzung der Spannungsqualität in Niederspannungsnetzen werden aktuell häufig nur anhand simulierter Daten verifiziert [1]–[4]. Um die Anwendbarkeit in der Realität sicherzustellen, überprüfen wir mehrere auf neuronalen Netzen basierende Methoden mit realen Messungen im Microgrid. Hierbei erreichen wir bei der Abschätzung der ersten 25 harmonischen Oberschwingungen trotz geringer Messgerätedichte einen mittleren quadratischen Fehler (MSE) von lediglich 1.1×10^{-5} .

Einführung

Im Zuge der Energiewende nimmt der Anteil dezentraler und auf Wechselrichtern basierender Erzeugungsanlagen im Stromnetz zu. Zeitgleich werden vermehrt nicht-lineare Verbraucher wie die Ladeinfrastruktur von Elektrofahrzeugen in der Niederspannung angeschlossen. Dadurch kann es vermehrt zu Störungen der Spannungsqualität in Netzbereichen kommen, die bislang kaum überwacht werden [5], [6]. Da Messungen der Spannungsqualität jedoch zu kostspielig sind, um das gesamte Niederspannungsnetz flächendeckend zu überwachen, werden intelligente Algorithmen benötigt, die von wenigen gemessenen Knoten auf ungemessene Knoten zurückschließen können.

Hierbei sind vor allem datenbasierte Algorithmen wie neuronale Netze vielversprechend, da sie die fehlende Verfügbarkeit aktueller Daten durch ein Training auf historischen oder simulierten Daten ausgleichen. In diesem Paper werden verschiedene Modelle miteinander verglichen und mithilfe gemessener Daten eines Labornetzes verifiziert.

Netzbeschreibung Microgrid

An der Technischen Hochschule Köln wurde zur Verifizierung der Algorithmik ein Microgrid aufgebaut, dessen schematischer Aufbau in Abbildung 1 zu sehen ist. Es verfügt über sechs steuerbare, dreiphasige Wechselrichter, die signifikante Störungen der Spannungsqualität verursachen und in verschiedene Schaltzustände versetzt werden können. Hierbei agieren die Wechselrichter entweder als Einspeiser in das Microgrid oder als Last und sind dafür auf der Gleichstromseite mit einem Batteriepool verbunden. Das nicht-lineare Verhalten eines Wechselrichters in verschiedenen Schaltzuständen auf Phase 1 sind in Abbildungen 2a und 2b dargestellt. Darüber hinaus ist das vorgelagerte Netz als Spannungsquelle des Microgrid ebenfalls eine Quelle harmonischer

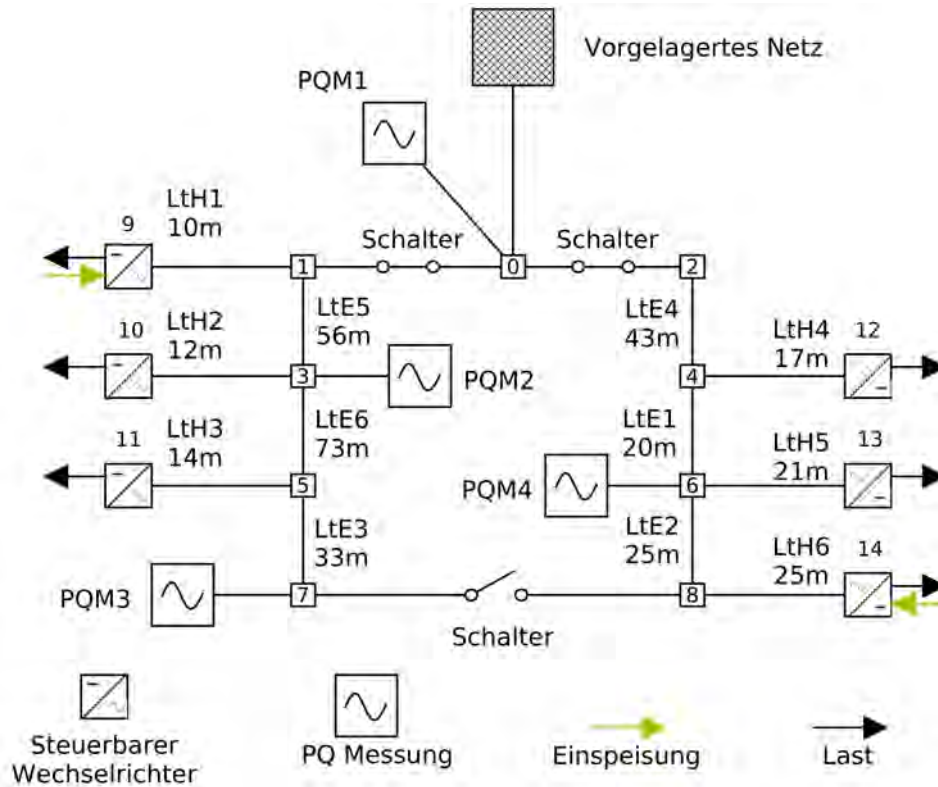
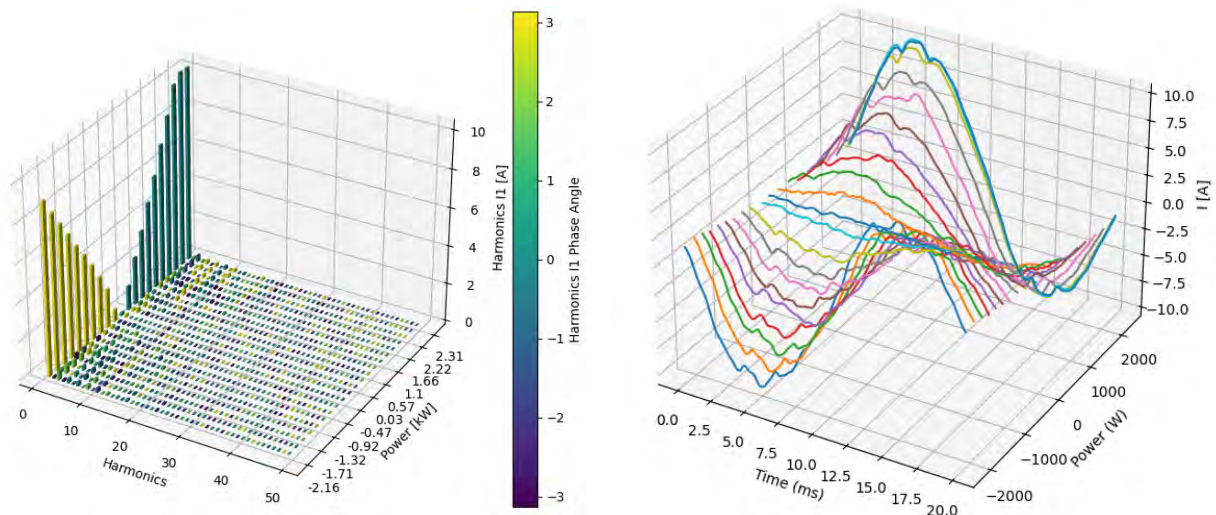


Abbildung 1: Schematischer einphasiger Netzplan des Microgrids. Spannungsqualitätsmessungen (PQM) messen harmonische Oberschwingungen an vier ausgewählten Knoten. Wechselrichter, die Erzeuger und Verbraucher in Haushalten repräsentieren, sind über Haushaltsleitungen (LtH) an das Netz angeschlossen. Das Netz besteht aus Erdleitungen (LtE) verschiedener Längen. PQM2 (Knoten 3) und PQM4 (Knoten 6) werden als Eingangswerte für die Schätzung genutzt.



(a) Harmonisches Spektrum mit Oberwellen auf der x-Achse, Lastpunkte auf der y-Achse und dem Betrag des Stroms auf der z-Achse. Die Balken sind anhand des Winkels in radians eingefärbt.

(b) Die aus dem gemessenen Spektrum rekonstruierte Wellenform zeigt das Ausmaß der harmonischen Störungen, die durch den Wechselrichter verursacht werden.

Abbildung 2: Gemessene Störungen des Wechselrichters 1 (Knoten 9 im Netzplan) über mehrere Lastpunkte. Alle Wechselrichter entsprechen dem Modell *Sontime E-S (UfE GmbH) Sinuswechselrichter* der Firma *FEG mbH*

Störungen. Vier Spannungsqualitätsmessgeräte (PQM) des Modells *a-eberle PQI-DA smart* messen GPS-synchronisiert den Netzzustand an ausgewählten Knoten in Form von komplexen Spannungszeigern. Zwei der Messungen werden als Eingangswerte für die Algorithmen genutzt, die davon ausgehend den Netzzustand der ersten 25 harmonischen Oberschwingungen an allen Knoten abschätzen. Verifiziert werden die Ergebnisse der Zustandsschätzung mit allen vier PQM.

Methodik

Zuerst wird ein digitaler Zwilling des Microgrids in der Simulationsumgebung OpenDSS erstellt [7]. Hierfür wurden die harmonischen Störungen sowohl der Wechselrichter als auch des vorgelagerten Netzes sowie die Leitungsbeläge vermessen und digitalisiert. Im nächsten Schritt werden eine hochvariante Simulation und eine realistische Simulation durchgeführt. Bei der hochvarianten Simulation werden jedem Knoten, der potenziell Störungen der Spannungsqualität verursacht, zufällig generierte harmonische Störspektren und zufällige Last- und Erzeugungsprofile hinterlegt. Die realistische Simulation nutzt die gemessenen Fehlerspektren der Wechselrichter jedoch weiterhin zufällige Last- und Erzeugungsprofile. Es wird darauf geachtet, dass insgesamt eine möglichst gleichmäßige Verteilung der Lastzustände über alle Knoten erreicht wird, um eine optimale Grundlage zum Training der neuronalen Netze zu schaffen. Die Simulationsergebnisse werden in 70% Trainingsdatensatz und 30% Validierungsdatensatz aufgeteilt und zum Training der KI-Modelle genutzt. Abbildung 3 zeigt




Abbildung 3: Ablaufplan der Erstellung und Verifizierung der KI-Modelle ausgehend von dem Microgrid

den Ablauf der Erstellung der Datensätze und der KI-Modelle.

Während klassische iterative Lösungsalgorithmen wie Weighted Least Squares (WLS) wohlbestimmte Gleichungssysteme benötigen, um zu konvergieren [8], können neuronale Netze auch ausgehend von wenigen Messpunkten genaue Schätzungen treffen. Neuronalen Netzen wird hierfür im Training beigebracht, von den zwei Eingangsmessungen auf alle Knoten zurückzuschließen. Während im *forward pass* Gewichte mit Inputs multipliziert werden, um über eine Aktivierungsfunktion Outputs zu erzeugen, werden im *backward pass* mithilfe des Gradientenverfahren die Gewichte der Verbindungen der Neuronen so angepasst, dass bei der Abschätzung der unbekanntenen Werte ein minimaler Fehler auf dem Validierungsdatensatz erzeugt wird [9].

Für diese Anwendung werden hier mehrere Modelle neuronaler Netze verwendet. In vollständig verbundenen (*fully-connected* oder *dense*) neuronalen Netzen (DNN) sind alle Neuronen einer Schicht mit allen Neuronen der nächsten Schicht verknüpft. In einem zweiten Modell wird die Netzstruktur in die Architektur des Modells eingepreßt in sogenannten *Physics-Aware Neural Networks* (PANN) [2], [4], [10]. In PANN sind lediglich jene Neuronen miteinander verknüpft, deren Äquivalente im Stromnetz ebenfalls benachbart sind. Hierdurch wird eine realistische Ausbreitung von Nachrichten durch das neuronale Netz modelliert. Die Architektur beider Modelle ist in Abbildung 4 dargestellt.

Darüber hinaus werden Eingangswerte mit einem gaußschem Rauschen versehen, um Ungenauigkeiten der Messgeräte darzustellen. Zudem wird neben den harmonischen Oberschwingungen ebenfalls die Grundfrequenz abgeschätzt. Dadurch enthält das Ergebnis der Schätzung sowohl eine Lastflussschätzung als auch die Schätzung von Spannungseinbrüchen und Überspannungen.

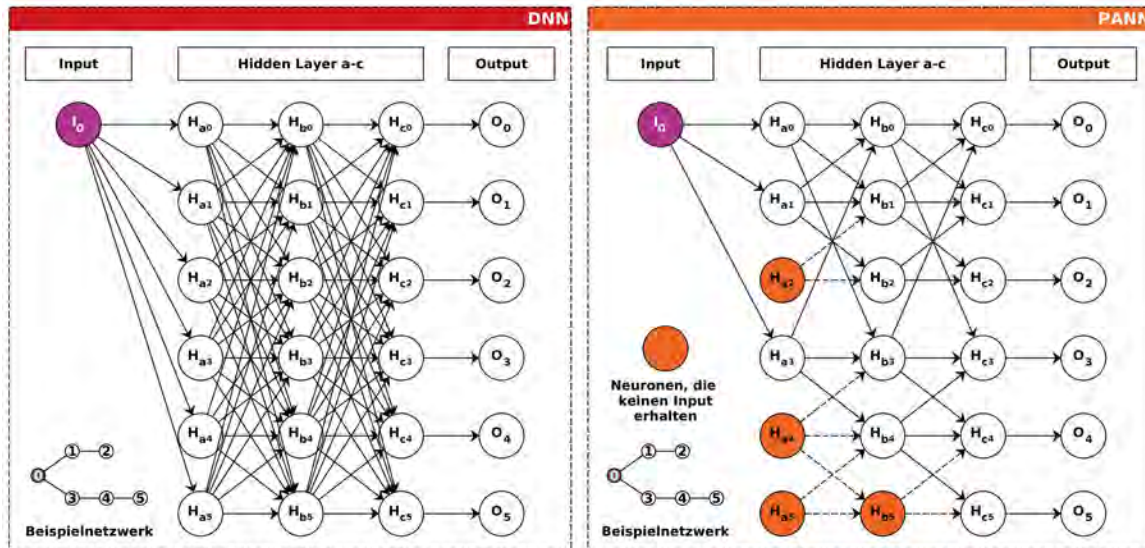


Abbildung 4: Modellarchitektur eines *Dense Neural Network* (DNN, links) und eines *Physics-Aware Neural Networks* (PANN, rechts) anhand eines Beispielnetzes mit einem Input. Im PANN sind lediglich die Neuronen miteinander verknüpft, die mit im Stromnetz benachbarten Knoten korrespondieren, während im DNN alle Neuronen mit denjenigen der nächsten Schicht verknüpft sind.

Ergebnisse

Auf dem im Microgrid gemessenen Testdatensatz erzielt das DNN einen MSE von 1.11×10^{-5} und das PANN einen MSE von 1.23×10^{-5} nach 7000 Epochen. Werden die normalisierten Eingangswerte mit einem Messrauschen in Normalverteilung mit Standardabweichung 0.01 versehen, steigt der MSE auf 3.55×10^{-5} (DNN) bzw. 4.19×10^{-5} (PANN). Dies zeigt, dass die Modelle auch bei verrauschten Werten weiterhin gute Abschätzungen treffen. Tabelle 1 zeigt den MSE für die zwei untersuchten

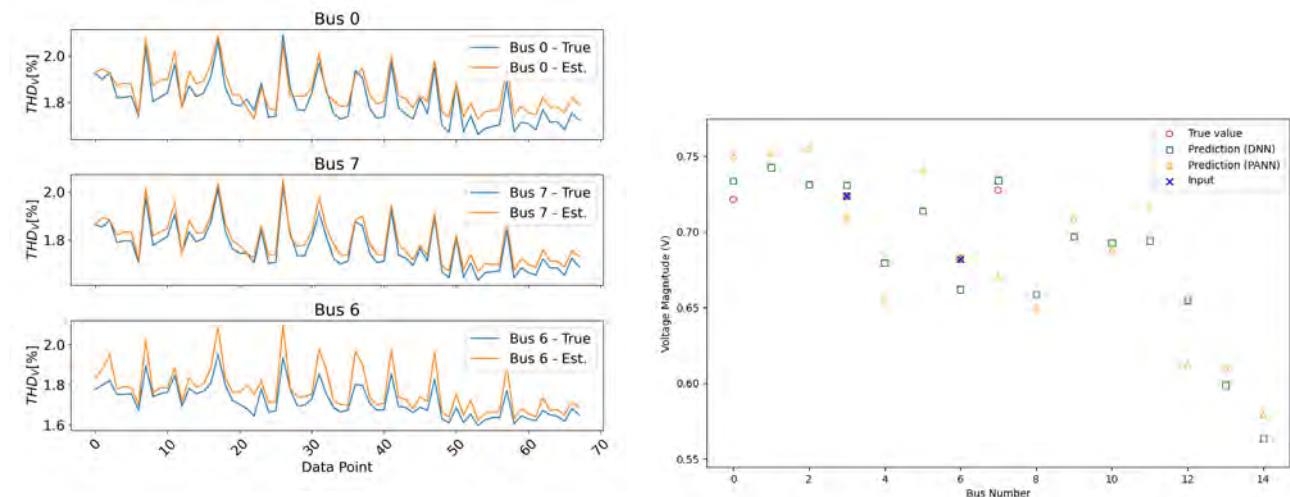
Tabelle 1: Mittlerer quadratischer Fehler (MSE) der Modelle über alle Harmonischen aufgeteilt nach Knoten. Knoten, deren Messungen als Eingangswerte genutzt wurden, sind kursiv markiert.

Modell	<i>Knoten 0</i>	<i>Knoten 3</i>	<i>Knoten 6</i>	<i>Knoten 7</i>
DNN	2.36×10^{-5}	1.27×10^{-6}	1.36×10^{-6}	1.8×10^{-5}
PANN	2.29×10^{-5}	2.95×10^{-6}	2.4×10^{-6}	2.13×10^{-5}

Modelle separat für jeden Knoten. Hier ist zu erkennen, dass auch die Knoten, die ausschließlich zur Verifizierung dienen und deren Werte dem Modell nicht bekannt sind, gut abgeschätzt werden. In Abbildung 5a sind die tatsächliche und die vorhergesagte Oberschwingungsgesamtverzerrungen an drei Knoten dargestellt. Abbildung 5b zeigt beispielhaft die geschätzten Werte in einem zufällig gewählten Datenpunkt des Testdatensatzes in der 7. Harmonischen.

Literaturverzeichnis

- [1] B. Azimian, R. S. Biswas, S. Moshtagh, A. Pal, L. Tong und G. Dasarathy, „State and Topology Estimation for Unobservable Distribution Systems Using Deep Neural Networks,“ *IEEE Transactions on Instrumentation and Measurement*, Jg. 71, S. 1–14, 2022, Conference Name: IEEE Transactions on Instrumentation and Measurement. DOI: 10.1109/TIM.2022.3167722.
- [2] A. S. Zamzam und N. D. Sidiropoulos, „Physics-Aware Neural Networks for Distribution System State Estimation,“ *IEEE Transactions on Power Systems*, Jg. 35, Nr. 6, S. 4347–4356, Nov. 2020, Conference Name: IEEE Transactions on Power Systems. DOI: 10.1109/TPWRS.2020.2988352.



(a) Die Oberschwingungsgesamtverzerrung (*Total Harmonic Distortion*, THD) wird durch das Modell (DNN) sowohl an dem Inputknoten 6 als auch an den dem Netzwerk unbekanntem Validierungsknoten 0 und 7 gut nachgebildet und insgesamt leicht überschätzt.

(b) In der 7. Oberwelle treffen sowohl das PANN als auch das DNN mit ihren Vorhersagen gut die Zielwerte.

Abbildung 5: Ergebnisse der Spannungsqualitätsschätzung für ausgewählte Modelle.

- [3] L. Zhang, G. Wang und G. B. Giannakis, „Distribution System State Estimation Via Data-Driven and Physics-Aware Deep Neural Networks,“ in *2019 IEEE Data Science Workshop (DSW)*, Juni 2019, S. 258–262. DOI: 10.1109/DSW.2019.8755581.
- [4] M.-Q. Tran, A. S. Zamzam, P. H. Nguyen und G. Pemen, „Multi-area distribution system state estimation using decentralized physics-aware neural networks,“ *Energies*, Jg. 14, Nr. 11, S. 3025, Jan. 2021, Number: 11 Publisher: Multidisciplinary Digital Publishing Institute. DOI: 10.3390/en14113025.
- [5] Y. Sanchez-Puentes, C. Argote-Parra, W. Lakatt-Benavides, J. Narvaez-Viana, J. Nuñez-Alvarez und J. Grimaldo-Guerrero, „Influence of photovoltaic systems on power quality problems,“ *International Journal of Energy Economics and Policy*, Jg. 13, Nr. 3, S. 185–190, 17. Mai 2023, Number: 3. DOI: 10.32479/ijeeep.14256.
- [6] H. Ping, L. Dong und Q. Xin, „Influence of Grid-connected Photovoltaic Systems on Power Quality,“ in *2019 IEEE 2nd International Conference on Automation, Electronics and Electrical Engineering (AUTEEE)*, Nov. 2019, S. 447–451. DOI: 10.1109/AUTEEE48671.2019.9033202.
- [7] R. C. Dugan, D. Montenegro und A. Ballanti, „The open distribution system simulator (OpenDSS),“ 2020.
- [8] E. Waffenschmidt, M. De Koster, C. Hotz, S. Baum und I. Stadler, „Decentralized grid control using power grid state estimation,“ in *27th International Conference on Electricity Distribution (CIRED 2023)*, Rome, Italy: Institution of Engineering and Technology, 2023, S. 3869–3873. DOI: 10.1049/icp.2023.0551.
- [9] D. E. Rumelhart, G. E. Hinton und R. J. Williams, „Learning representations by back-propagating errors,“ *Nature*, Jg. 323, Nr. 6088, S. 533–536, Okt. 1986, Number: 6088 Publisher: Nature Publishing Group. DOI: 10.1038/323533a0.
- [10] P. Mack, M. de Koster, P. Lehnen, E. Waffenschmidt und I. Stadler, „Power Quality State Estimation in Verteilnetzen auf Basis Neuronaler Netze,“ München, 29. Nov. 2023.