

Monitoring in der Mittelspannungsebene mit künstlichen neuronalen Netzen – Eine Validierung der Methodik auf Basis von gemessenen Ortsnetzstationen

Marcel Dipp, Jan-Hendrik Menke, Sebastian Wende - von Berg,
Andrea Maurus, Tobias Kerber, Martin Braun

Inhalt

1 Hintergrund und Motivation

2 KNN-Monitoring: Grundlagen und Methodik

3 Ergebnisse der Validierung

4 Zusammenfassung

Inhalt

1 Hintergrund und Motivation

2 KNN-Monitoring: Grundlagen und Methodik

3 Ergebnisse der Validierung

4 Zusammenfassung

Hintergrund und Motivation

Mittelspannungsnetze verfügen aufgrund ihrer historisch bedingten Auslegung über eine geringe Anzahl an Messeinrichtungen



- Voranschreitenden Ausbau volatiler dezentraler Erzeugungsanlagen [1]
- Zubau von Ladesäulen für E-Kfz [2]



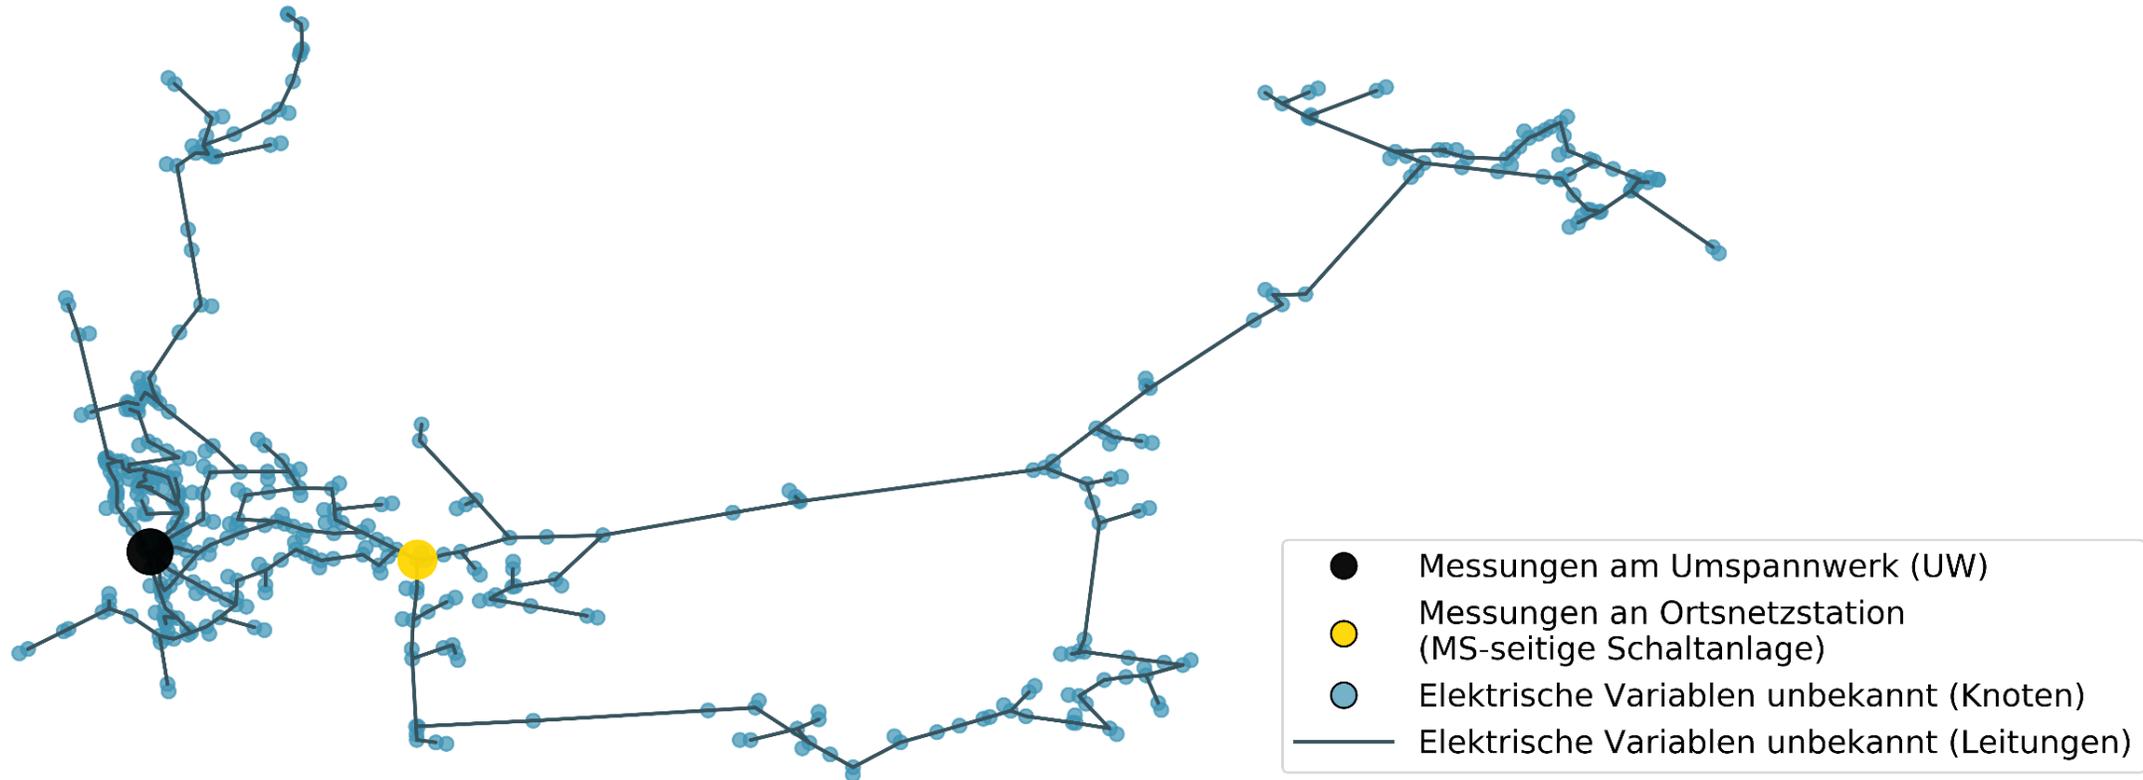
Erhöht Wahrscheinlichkeit für Grenzwertverletzungen innerhalb der Mittelspannungsebene [1]



Monitoring-Methoden haben an Relevanz gewonnen, um sicherheitsrelevante Variablen zu schätzen und somit **Transparenz und Sichtbarkeit** zu erzeugen

Hintergrund und Motivation

- In der Regel sind nur die HS/MS-Umspannstationen vollständig ausgemessen
- Weitere Messungen können sich vereinzelt an MS/NS-Ortsnetzstationen befinden
- Der aktuelle Zustand der Systemgrößen ist mit Ausnahme der wenigen verfügbaren Messwerte unbekannt



Inhalt

1 Hintergrund und Motivation

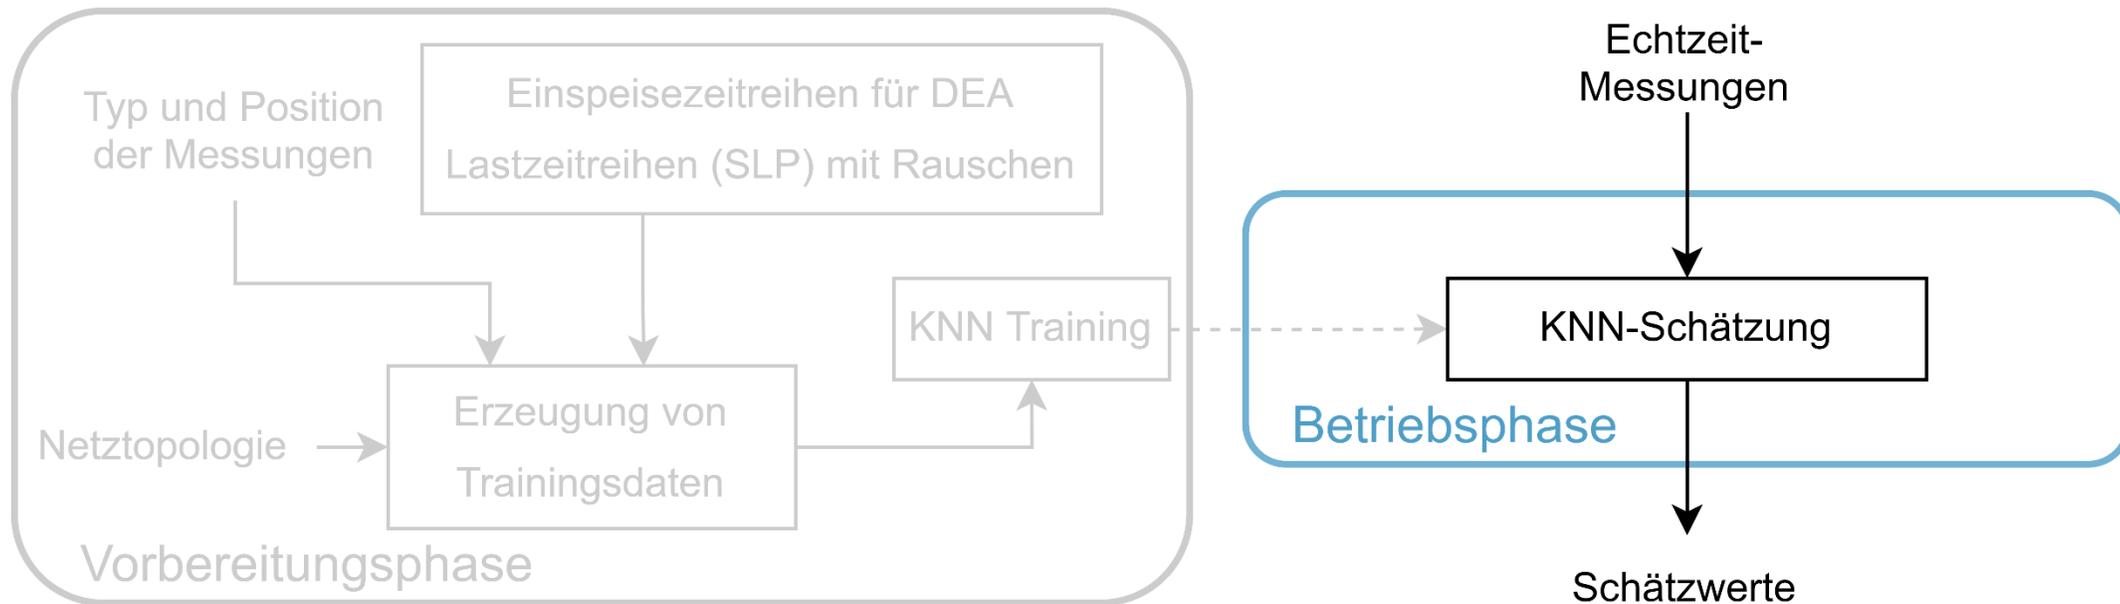
2 KNN-Monitoring: Grundlagen und Methodik

3 Ergebnisse der Validierung

4 Zusammenfassung

KNN – Monitoring: Grundlagen und Methodik

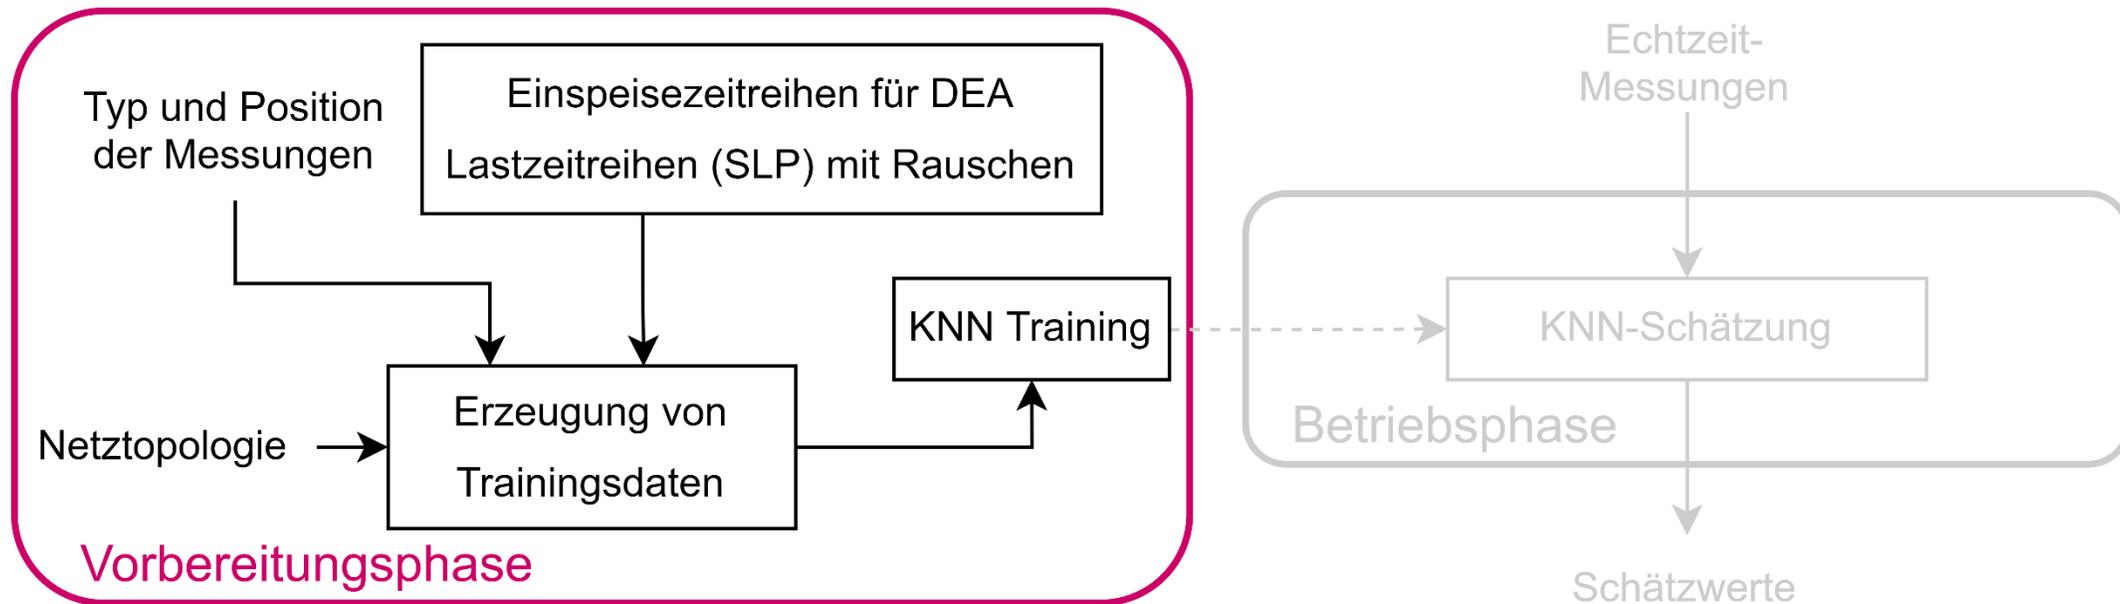
In der **Betriebsphase** schätzt das trainierte KNN mithilfe der Messungen in Echtzeit die elektrischen Parameter wie Höhe der Knotenspannungen V_k , Stromfluss I_l , und Wirkleistungsfluss P_l für die Knoten K bzw. Leitungen l .



In der Vorbereitungsphase wird eine möglichst hohe Anzahl an Netzzuständen bei angemessenem Rechenaufwand abgebildet. Hierbei werden die Positionen aller Messstellen sowie vorhandenes Messrauschen berücksichtigt.

KNN – Monitoring: Grundlagen und Methodik

In der Betriebsphase schätzt das trainierte KNN mithilfe der Messungen in Echtzeit die elektrischen Parameter wie Höhe der Knotenspannungen V_k , Stromfluss I_l , und Wirkleistungsfluss P_l für die Knoten K bzw. Leitungen l .



In der **Vorbereitungsphase** wird eine möglichst hohe Anzahl an Netzzuständen bei angemessenem Rechenaufwand abgebildet. Hierbei werden die Positionen aller Messstellen sowie vorhandenes Messrauschen berücksichtigt.

KNN – Monitoring: Vorgehensweise der Validierung

(1) Die **Vorbereitungsphase** wird durchlaufen:

- Hierbei werden die Messstellen des HS/MS-Umspannwerks einbezogen
- Die Messungen der MS/NS-Ortsnetzstation (MS-seitig) bleiben unberücksichtigt
- Trainingszeitraum: Jahr 2016 [h]

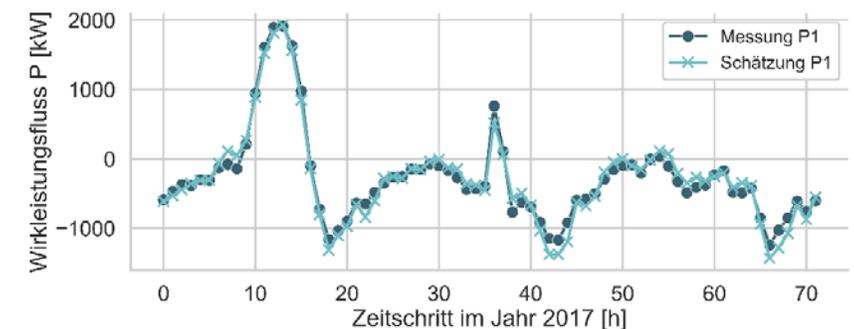
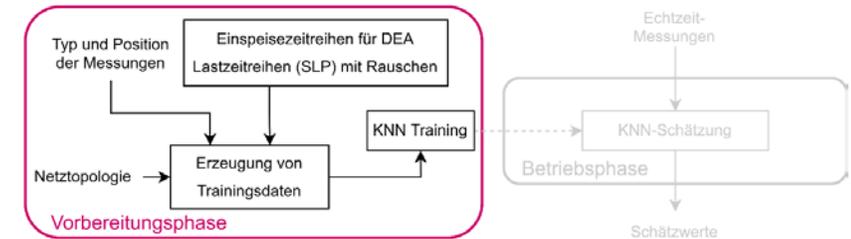


(2) Die KNN schätzen in der **Betriebsphase** die elektrischen Variablen des gesamten Netzgebietes:

- Eingangswerte: Reale Messwerte der Zeitreihen des HS/MS-Umspannwerks
- Testzeitraum: 01.01.2017 - 01.05.2017 [h]



(3) Vergleich zwischen den Schätzergebnissen der KNN mit den realen Messreihen der MS/NS-Ortsnetzstation (MS-seitig)



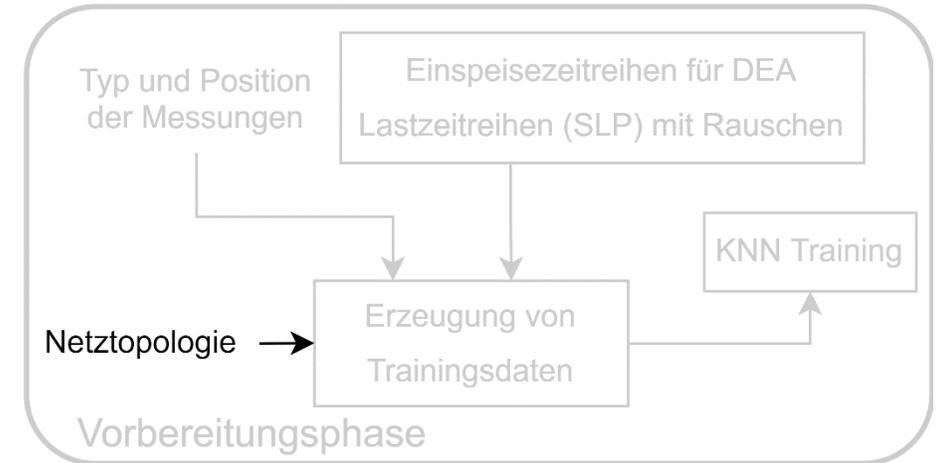
KNN – Monitoring: Netztopologie

20 kV Mittelspannungsnetz:

- **Radiale Betriebsweise**
 - 7 MS-Sammelschienenabgänge
 - HS/MS-Umspannwerk verfügt über eine MS-Sammelschiene

- **111 Lasten**
 - Aggregierte NS-Lasten
 - Gewerbelasten (NS)

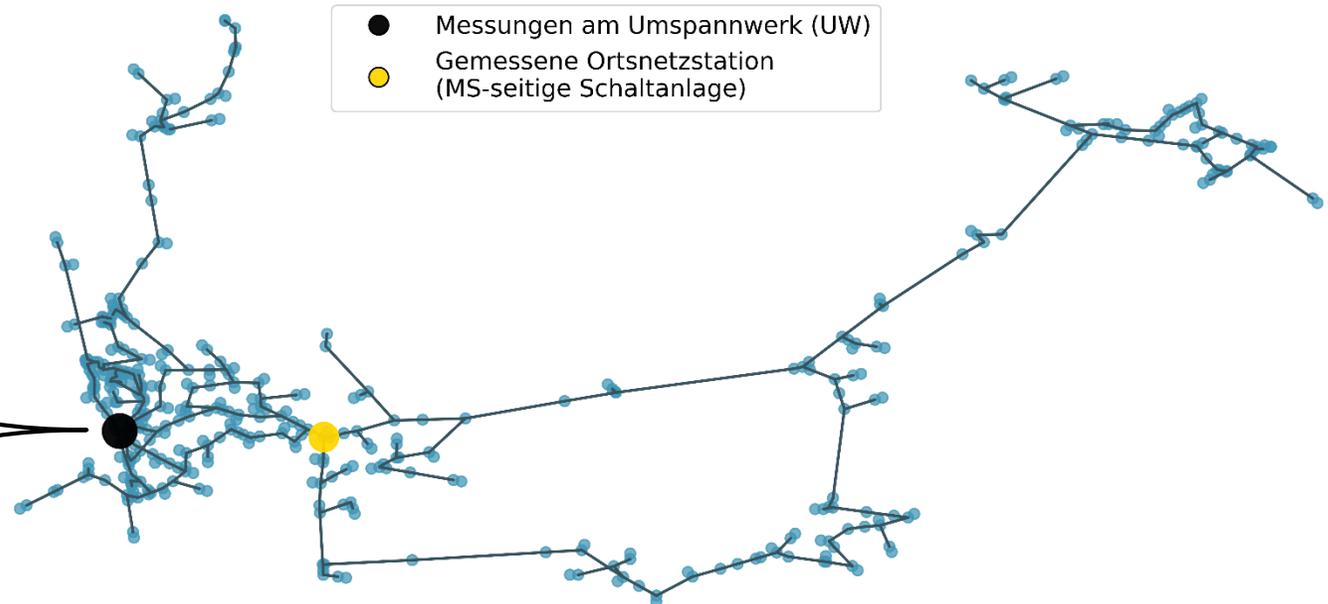
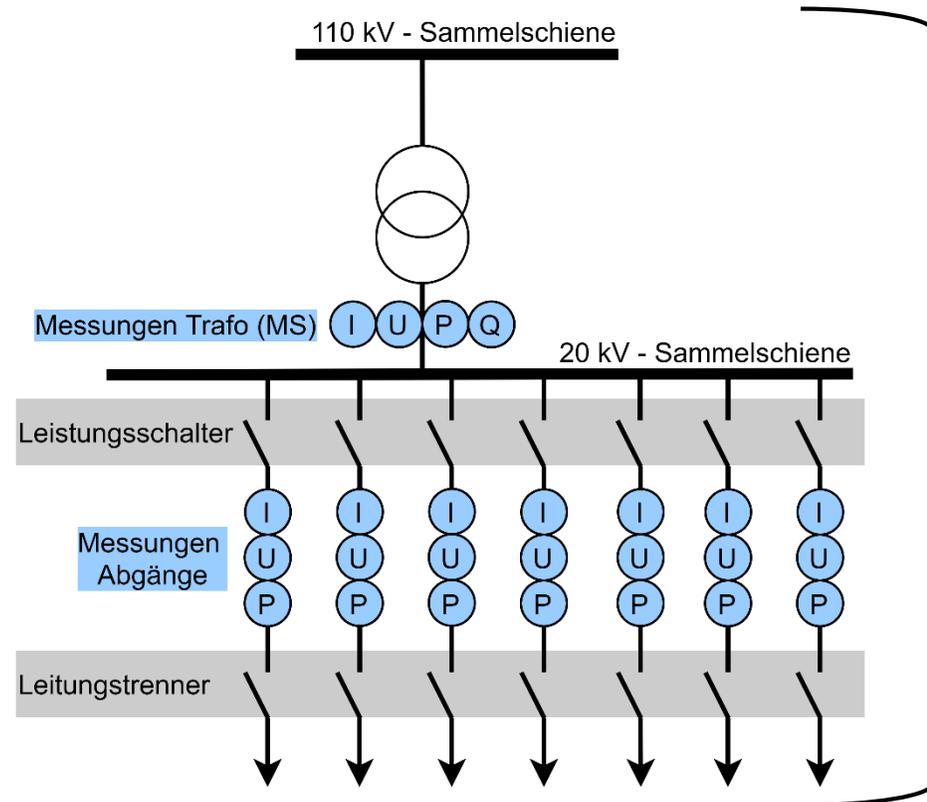
- **119 DEA (~19.5 MW)**
 - Solarparks
 - Aggregierte Photovoltaikanlagen aus der NS
 - Biogasanlagen
 - Wasserkraftanlagen



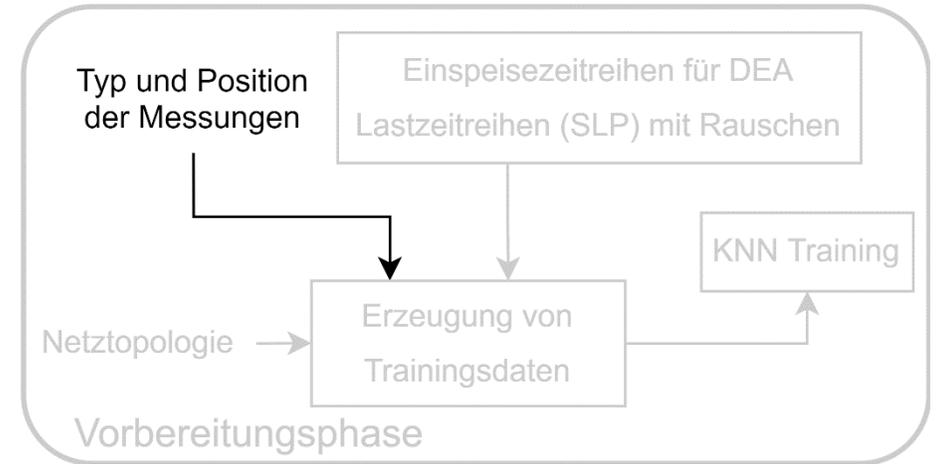
KNN – Monitoring: Typ und Position der Messungen

Messstellen:

- HS/MS-Umspannwerk
 $m_{\text{Trafo}_{I,V,P,Q}} + m_{\text{Abgang}_{I,V,P,1-7}} = 4 + 21 = 25$
- MS/NS-Ortsnetzstation (MS-seitiges Schaltwerk)



- Messungen am Umspannwerk (UW)
- Gemessene Ortsnetzstation (MS-seitige Schaltanlage)



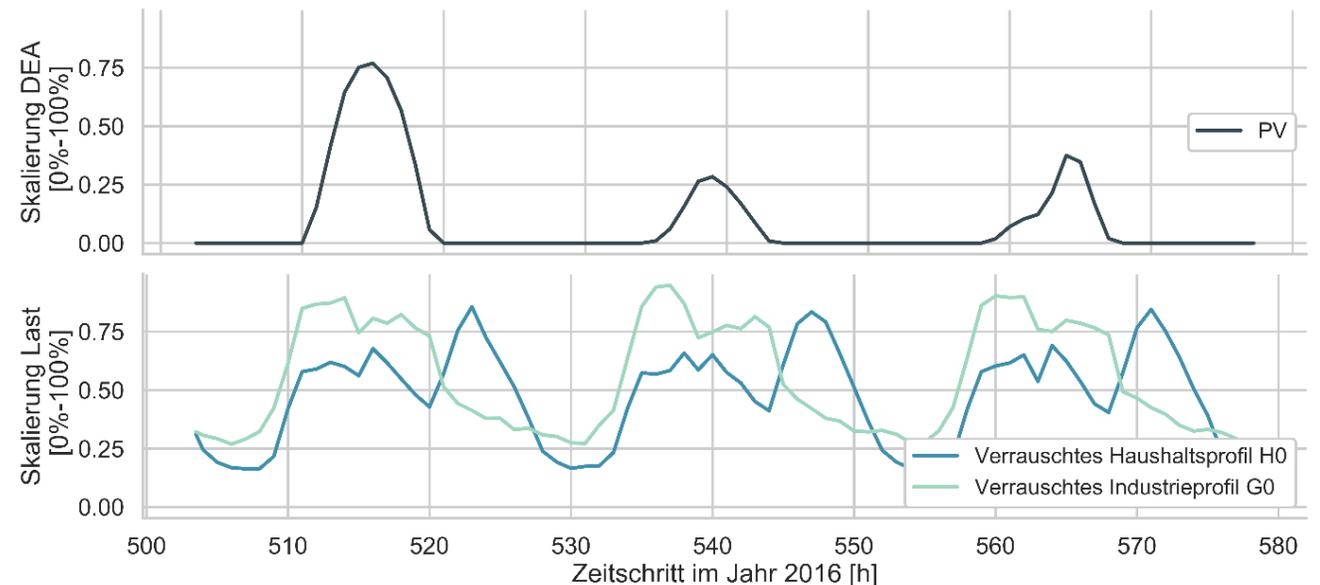
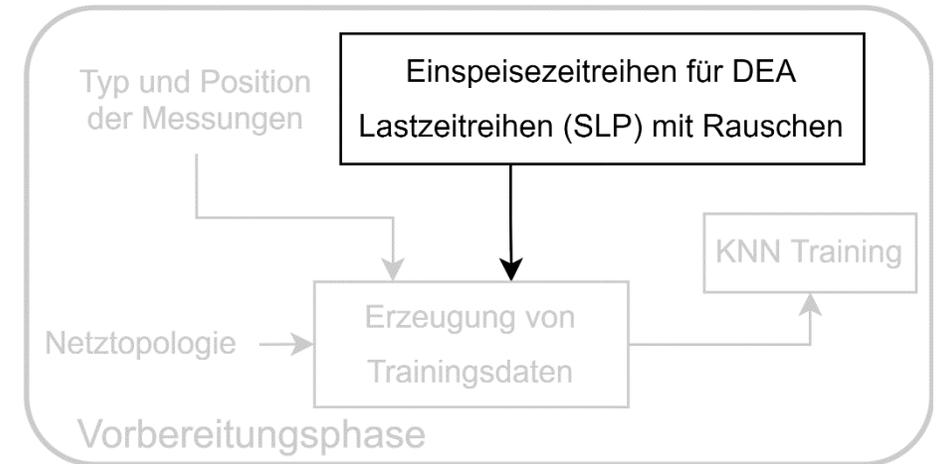
KNN – Monitoring: Einspeise- und Lastzeitreihen

Einspeisezeitzeihen

- Photovoltaikanlagen: Erstellung mittels renewables.ninja [3]
- Wasserkraftanlagen: Durchgängiger Betrieb bei Nennleistung
- Biogasanlagen: Verwendung realer Zeitreihen

Lastzeitreihen:

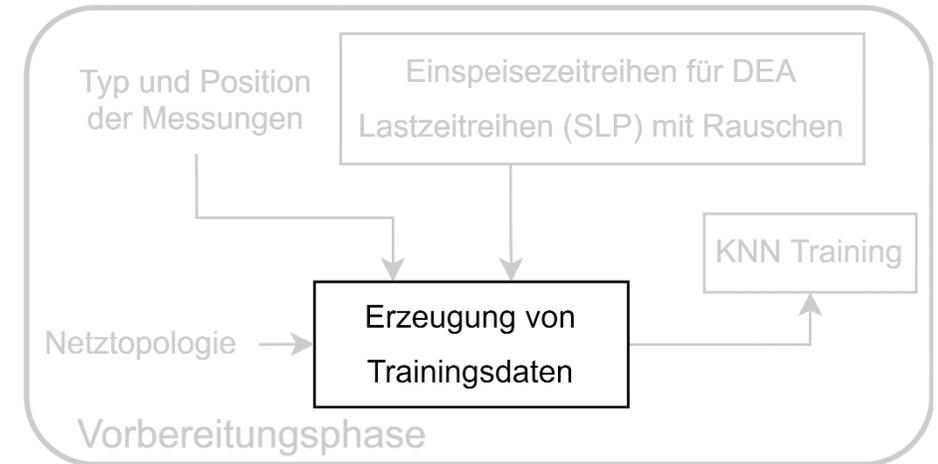
- Verrauschte Standardlastprofile:
 - Standardlastprofile für Haushalte (SLP-H0)
 - Standardlastprofile für Gewerbe (SLP-G0)
- Reale Lastgänge von Gewerbekunden



KNN – Monitoring: Erzeugung von Trainingsdaten

Der gewählte Trainingszeitraum in stündlicher Auflösung erstreckt sich über das Jahr 2016

Die Netzstruktur, sowie Platzierung, Typ, und Messrauschen aller Messgeräte werden in pandapower [4] abgebildet



Iterativer Prozess

(1) Skalierung der Last- und Erzeugungsanlagen für jeden Zeitschritt entsprechend der Zeitreihen



(2) Leistungsflussberechnung für den derzeitigen Zustand



(3) Speichern der Ergebnisse P, U, I, und der zugehörigen Messwerte

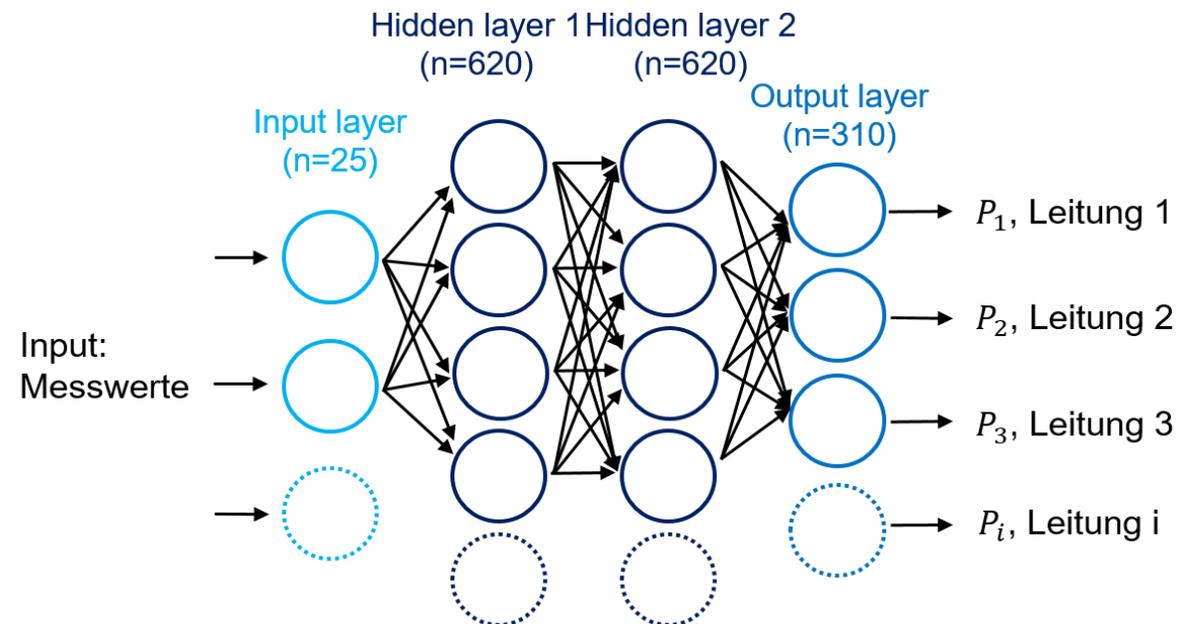
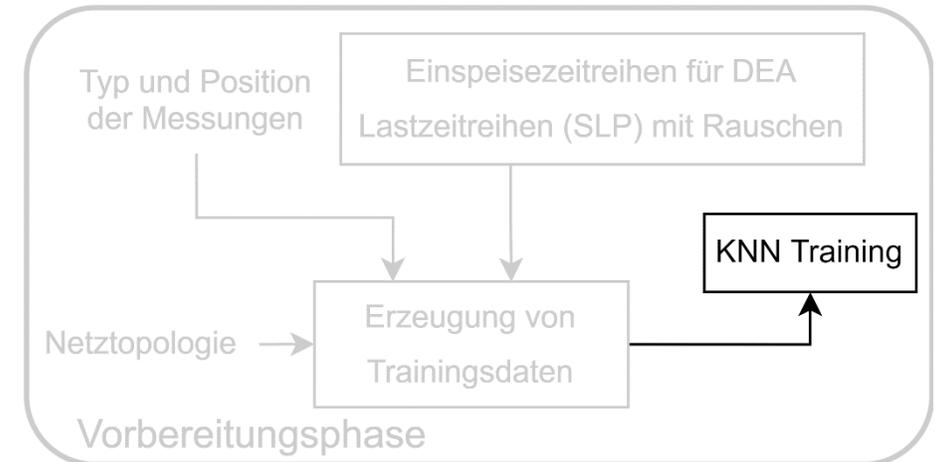


KNN – Monitoring: Training und Hyperparameter

Erstellung der KNN mittels PyTorch [5]

Hyperparameter des KNN mit Basisarchitektur „multilayer perceptron“:

- Größe der Hidden layer: 2x Output layer
- Aktivierungsfunktionen:
 - ReLU (Hidden layers) | Linear (Output layer)
- Trainings-Epochen: 500
- Batch-Größe : 64
- Lernrate: 5e-4
- Optimierer: Adam



Inhalt

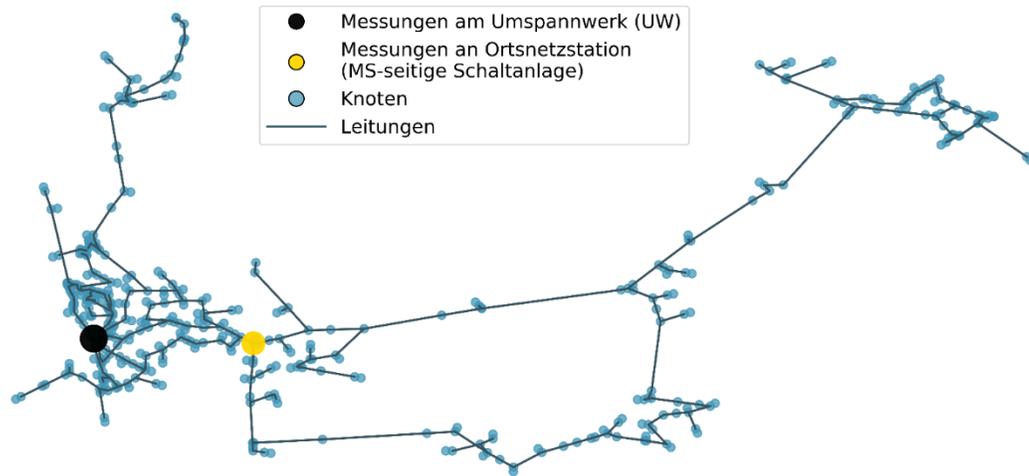
1 Hintergrund und Motivation

2 KNN-Monitoring: Grundlagen und Methodik

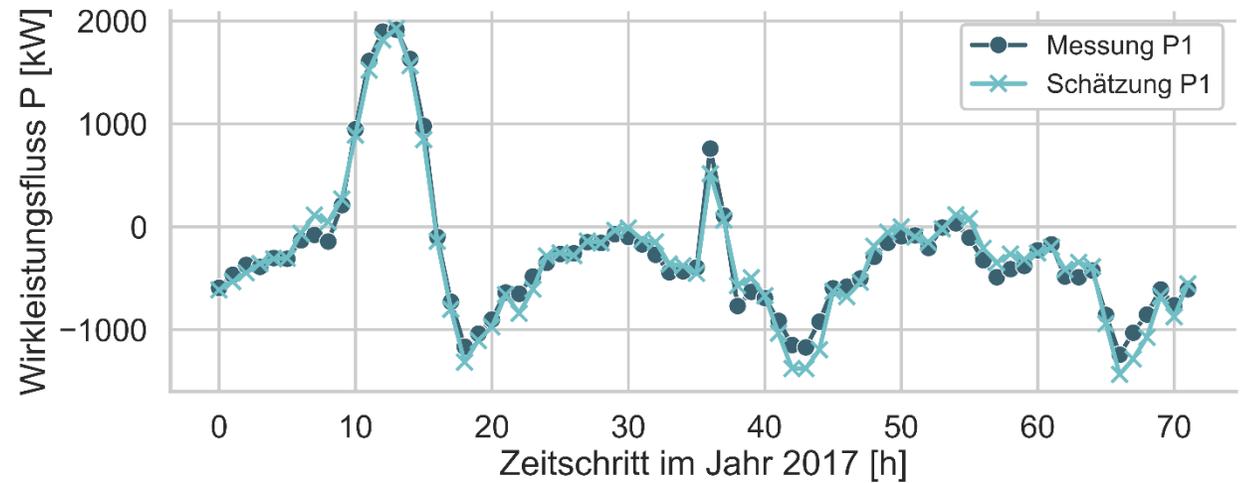
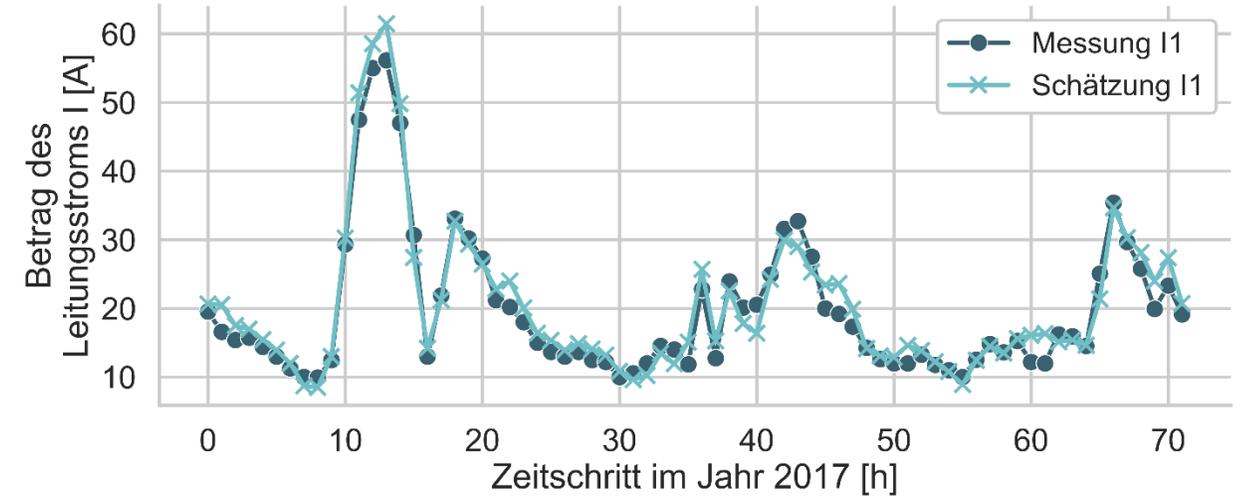
3 Ergebnisse der Validierung

4 Zusammenfassung

Ergebnisse der Validierung

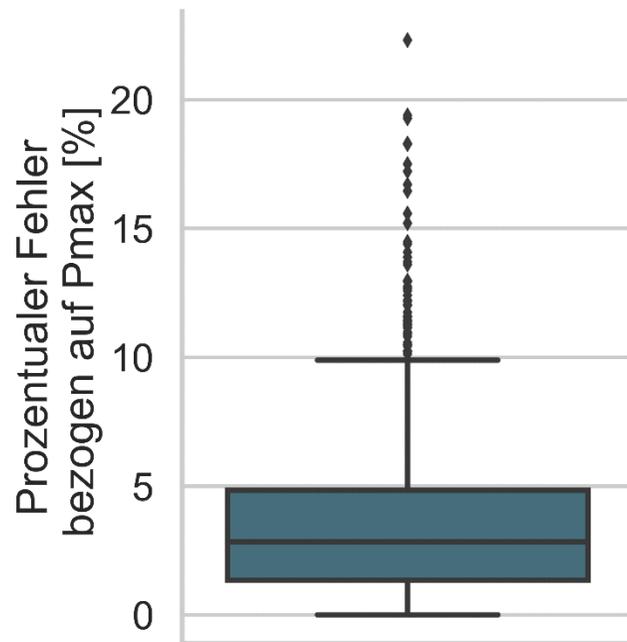


Testzeitraum: 01.01.2017 - 01.05.2017

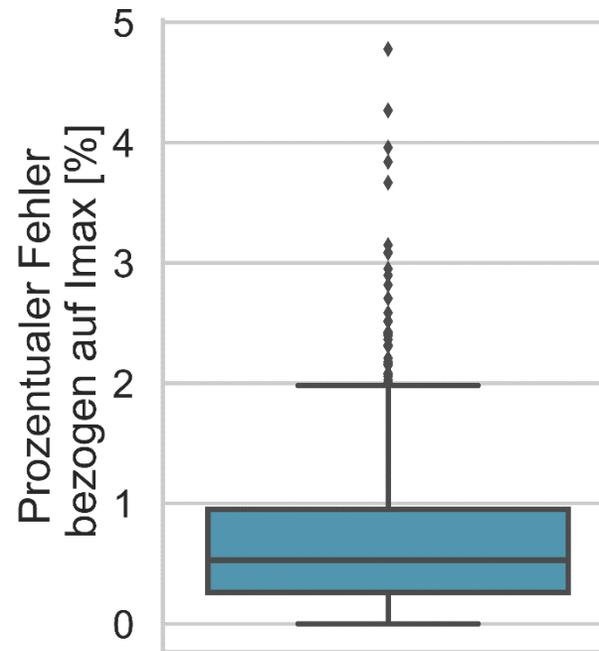


Ergebnisse der Validierung - Schätzfehler

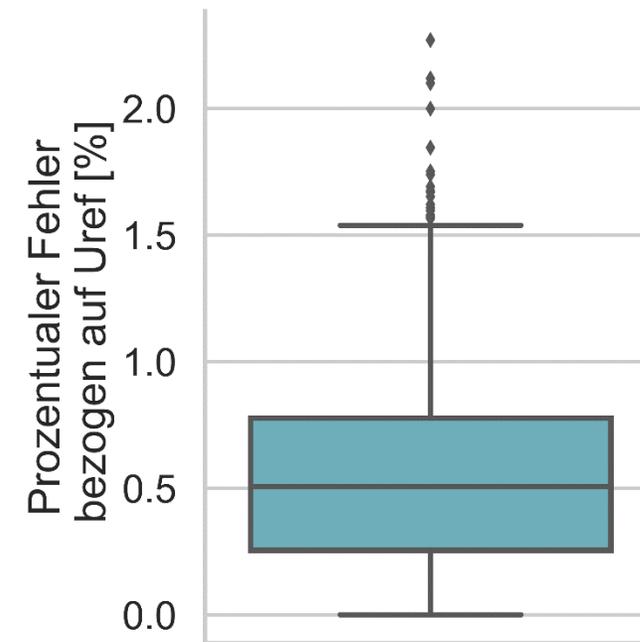
Abweichungen für den gesamten Testzeitraum vom 01.01.2017 bis 01.05.2017:



Schätzfehler von P [%]
Mean \pm Std.: 3.62 ± 3.21 %
(max.: 22.31 %)



Schätzfehler von I [%]
Mean \pm Std.: 0.68 ± 0.61 %
(max.: 4.77 %)



Schätzfehler von U [%]
Mean \pm Std.: 0.56 ± 0.37 %
(max.: 2.27 %)

Inhalt

1 Hintergrund und Motivation

2 KNN-Monitoring: Grundlagen und Methodik

3 Ergebnisse der Validierung

4 Zusammenfassung

Zusammenfassung - Methodik

- Validierung des Monitoring Verfahrens auf Basis von realen Messzeitreihen.
- Bereitstellung der Trainingsdaten durch Leistungsflussberechnungen mittels Einspeise- und Lastzeitreihen.
- Für die Eingangsparameter wurden ausschließlich die Messungen der HS/MS-Umspannstation berücksichtigt.
- Vergleich zwischen den Schätzungen des Monitorings und den realen Messzeitreihen der MS/NS-Ortsnetzstation (MS-seitig) im Testzeitraum: 01.01.2017 - 01.05.2017.

Zusammenfassung - Ergebnisse

- Mittelwert des Schätzfehlers der elektrischen Variablen Wirkleistungsfluss P , Leitungsstrom I , und Spannung U :
 $P/I/U$: 3.62 % / 0.68 % / 0.56 %.
- Für einzelne Zeitschritte erhöhte Abweichungen durch unzureichende Abbildung von Einspeise- und Lastverhalten.
- Die MS-seitig gemessene MS/NS-Ortsnetzstation repräsentiert nur einen Ausschnitt des gesamten Mittelspannungsnetzes.

Vielen Dank für die Aufmerksamkeit!

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). Die Verantwortung für die Inhalte liegt bei den Autoren.

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

Quellen

- [1] Deutsche-Energie-Agentur: dena Verteilnetzstudie. Ausbau- und Innovationsbedarf der Stromverteilnetze in Deutschland bis 2030, Dezember 2013.
- [2] <https://www.bundesregierung.de/resource/blob/975232/1673502/768b67ba939c098c994b71c0b7d6e636/2019-09-20-klimaschutzprogramm-data.pdf?download=1>
- [3] Pfenninger, Stefan; Staffell, Iain: Long-term patterns of European PV output using 30 years of validated hourly reanalysis and satellite data. *Energy*, 114:1251 – 1265, 2016.
- [4] Thurner, L.; Scheidler, A.; Schäfer, F.; Menke, J.; Dollichon, J.; Meier, F.; Meinecke, S.; Braun, M.: 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; Chintala, Soumith; Chanan, Gregory; Yang, Edward; DeVito, Zachary; Lin, Zeming; Desmaison, Alban; Antiga, Luca; Lerer, Adam: Automatic differentiation in PyTorch. In: NIPS-W. 2017.
- [6] Menke, Jan-Hendrik; Bornhorst, Nils; Braun, Martin: Distribution System Monitoring for Smart Power Grids with Distributed Generation Using Artificial Neural Networks. *International Journal of Electrical Power and Energy*, 113:472-480, December 2019.