

# Monitoring in Niederspannungsnetzen mit Verfahren der künstlichen Intelligenz – Validierung der Methodik in einem realen Stromnetz

Andreas Winter<sup>1(\*)</sup>, Selina Prinz<sup>2</sup>, Johannes Diegler<sup>2</sup>, Michael Igel<sup>1</sup>,  
Peter Schegner<sup>3</sup>

<sup>1</sup>Hochschule für Technik und Wirtschaft des Saarlandes, Goebenstraße 40,  
[andreas.winter@htwsaar.de](mailto:andreas.winter@htwsaar.de), [www.htwsaar.de](http://www.htwsaar.de)

<sup>2</sup>VSE Verteilnetz GmbH, Heinrich-Böcking-Straße 10, 66121 Saarbrücken,  
[selina.prinz@vse-verteilnetz.de](mailto:selina.prinz@vse-verteilnetz.de), [www.vse-verteilnetz.de](http://www.vse-verteilnetz.de)

<sup>3</sup>Technische Universität Dresden, 01069 Dresden,  
[peter.schegner@tu-dresden.de](mailto:peter.schegner@tu-dresden.de), [www.tu-dresden.de](http://www.tu-dresden.de)

**Kurzfassung:** Die Energiewende mit dem Ausstieg aus der fossilen Stromerzeugung, dem weiteren Ausbau erneuerbarer Energien auf der Verteilnetzebene und dem Weg hin zur Elektrifizierung der Mobilität stellt Verteilnetzbetreiber vor große Herausforderungen, besonders bei der Netzplanung und dem Netzbetrieb. Die Volatilität von Lasten und erneuerbaren Energien erschwert die Detektion von Überlastsituationen und Spannungsbandverletzungen.

Innerhalb der Netzplanung werden zunehmend anlagenscharfe Prognoseprofile oder probabilistische Ausfallsimulationen eingesetzt. Die daraus resultierende Vielzahl an Lastflusszenarien lässt sich nur mit hohem Rechenaufwand analysieren und bewerten. Verfahren der Künstlichen Intelligenz (KI) bieten ein großes Potenzial für die performante Verarbeitung großer Datenmengen und bahnen den Weg hin zu innovativen Technologien in der Netzsimulation. Die vorliegende Arbeit zeigt die Anwendung einer KI-basierten Lastflussberechnung in einem realen Niederspannungsnetz und vergleicht diese mit klassischen Verfahren.

Ein weiterer Fokus liegt auf der Netzzustandsschätzung als wichtiger Bestandteil der Netzbetriebsführung. Die etablierten Verfahren zur Schätzung von Netzzuständen auf der Hoch- und Höchstspannungsebene lassen sich in Niederspannungsnetzen aufgrund fehlender Beobachtbarkeit nur bedingt einsetzen. Diese Arbeit stellt einen KI-basierten Ansatz für die Netzzustandsschätzung vor und wendet diesen in einem realen Stromnetz an. Die Schätzgenauigkeit des Verfahrens wird anhand realer Messungen validiert.

**Keywords:** Künstliche Intelligenz, Monitoring, Lastflussberechnung, Niederspannungsnetz

## 1 Einleitung

Motiviert durch die Dekarbonisierung des Stromsektors sehen sich Netzbetreiber mit dem weiteren Ausbau von dezentralen Erzeugungsanlagen, variablen und sektorgekoppelten Lasten und einem steigenden Stromverbrauch konfrontiert. Die Folgen sind eine zunehmende Volatilität von Stromeinspeisung und -bezug und eine damit einhergehende stärkere Auslastung der Verteilnetzebene mit häufigen Last- und Erzeugungsspitzen. Gerade in den Niederspannungsnetzen sind nur wenige Ortsnetzstationen überwacht. Nur in seltenen Fällen sind Messsysteme auch innerhalb der Stromnetze, z. B. in Kabelverteilerschränken, installiert. Der Zubau

von weiteren Messsystemen, der für eine zuverlässige Erkennung von Betriebsmittelüberlastungen und Spannungsbandverletzungen erforderlich ist, lässt sich nur mit einem hohen wirtschaftlichen und technischen Aufwand umsetzen. Durch die Entwicklung innovativer Lösungen für das Monitoring bei einer geringen Anzahl an Messsystemen kann der wirtschaftliche Aufwand reduziert werden. Vor dem Hintergrund des großen Potentials von Systemen der KI wird in dieser Arbeit eine KI-basierte Netzsimulation entwickelt, die die klassische Netzberechnung mit Verfahren des maschinellen Lernens kombiniert. Die zentrale Fragestellung lautet: Lässt sich der Netzzustand in weit ausgedehnten Niederspannungsnetzen aber nur wenigen Messsystemen hoch performant analysieren und lassen sich Handlungsempfehlungen und Ausbaumaßnahmen mit geringen Rechenzeiten planen?

## 2 Beschreibung des untersuchten Niederspannungsnetzes

Bei dem untersuchten Stromnetz handelt es sich um ein ländliches Niederspannungsnetz mit einer Leitungslänge von ca. 71 km. Insgesamt versorgt das Stromnetz 1087 Verbraucherlasten mit 8 Ladesäulen für Elektrofahrzeuge, 92 Wärmepumpen und enthält 63 PV-Anlagen. Die Netztopologie ist in Abbildung 1 dargestellt (a) Stromnetzschemaplan und b) Ausschnitt aus der Stromnetzmodellierung im Netzberechnungsprogramm ATPDesigner [1]).

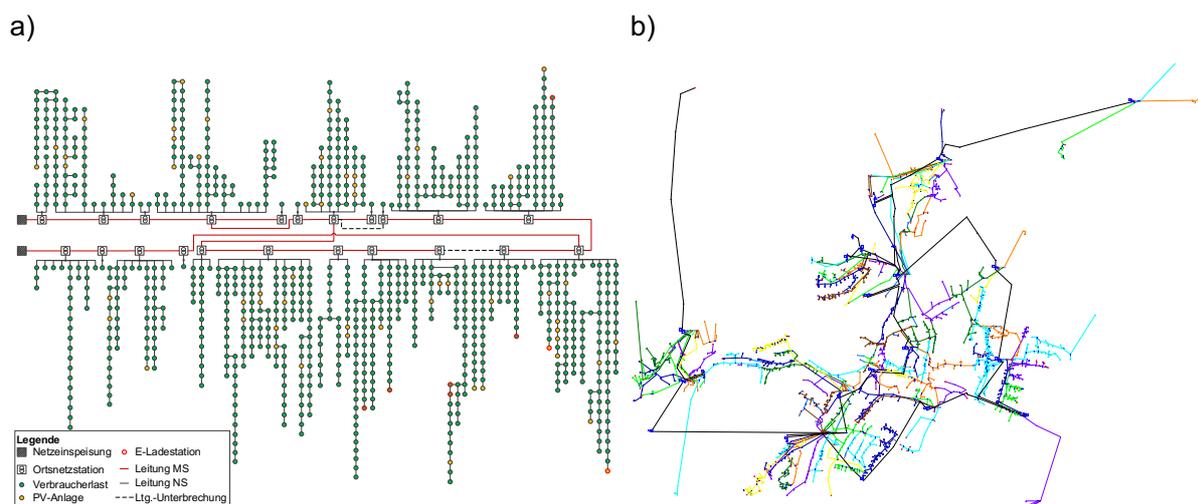


Abbildung 1: Netztopologie des untersuchten Niederspannungsnetzes

Die Validierung der KI-basierten Berechnung von Lastflüssen (KI-LF) [2] erfolgt für das vollständige Niederspannungsnetz und die Validierung der KI-basierten Netzzustandsschätzung (KI-SE) [3] im Abgang nach Abbildung 2. Dieser Abgang enthält 18 Verbraucherlasten, darunter eine Wärmepumpe, sechs Photovoltaikanlagen und eine Ladesäule für Elektrofahrzeuge.

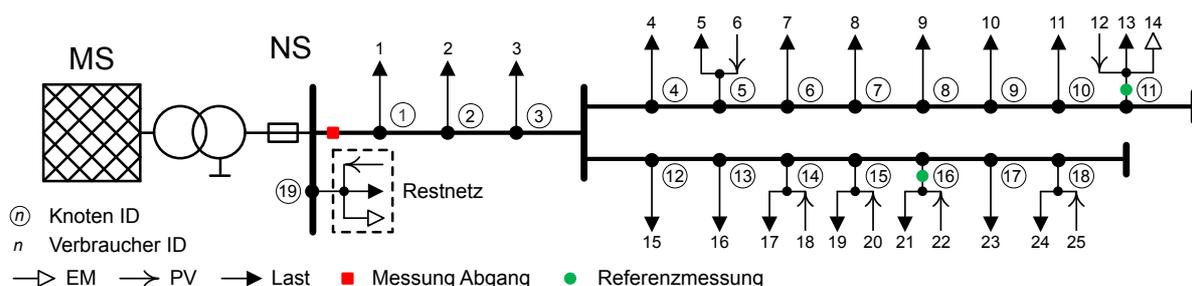


Abbildung 2: Abgang für die Validierung der KI-SE

Die insgesamt 637 m lange Leitung besteht zu 183 m aus Hausanschlussleitungen des Typs NAYCWY 3x35/35, 436 m NAYCWY 3x150/150, 12 m NAYY-J 4x150 und 7 m Privatkabel. Die Abgangsmessungen dienen als Eingabegrößen für die KI-SE und die Referenzmessungen zur Validierung des Verfahrens.

### 3 Methodik und Vorgehensweise

Die KI-basierte Netzsimulation [4] besteht aus drei Hauptkomponenten (Abbildung 3):

**(A) Schnittstelle zu einem Geoinformationssystem (GIS):** Mit einer Ausdehnung von ca. 1.354.600 km Leitungslänge [5] enthalten Niederspannungsnetze viel mehr Betriebsmittel als Mittel- und Hochspannungsnetze. Ein effizienter manueller Aufbau der Stromnetze in Netzrechnungsprogrammen ist nicht möglich. Sämtliche ortsbezogene Informationen von Betriebsmitteln eines Stromnetzes werden in einem GIS gespeichert und verwaltet. Aus der zugrunde liegenden Datenbank lassen sich somit sowohl topologische Informationen als auch spezifische Betriebsmitteldaten exportieren. Erfolgt ein Import der exportierten Daten in ein Netzrechnungsprogramm, so steht mit nur geringen manuellen Anpassungen ein Niederspannungsnetz mit großer Ausdehnung als mathematisches physikalisches Netzmodell in der Netzberechnung für weitere Untersuchungen zur Verfügung. In der vorliegenden Arbeit werden topologische Daten und Betriebsmitteldaten für eine gesamte Ortsgruppe aus einer Datenbank exportiert, aufbereitet, automatisiert in ein Netzberechnungsprogramm importiert und verarbeitet.

**(B) Klassische Stromnetzberechnung zur Datengenerierung:** Der gesamte Prozess beim Training von KI-Systemen hängt primär von der Qualität und Menge der Eingabedaten ab [6]. Für das Training der KI-Modelle werden in einer klassischen Netzberechnung mit Hilfe eines Fallgenerators [2] eine Vielzahl relevanter Lastflussszenarien berechnet und in einer Datenbank gespeichert. Ein Vorteil der synthetischen Datengenerierung im Vergleich zu historischen Daten besteht darin, dass auch zukünftige Entwicklungen in der Stromversorgung, z. B. die Elektromobilität oder Wärmepumpen, mit einbezogen werden können. In einem Vorverarbeitungsschritt für das Training der KI-Modelle werden diese Daten analysiert und aufbereitet.

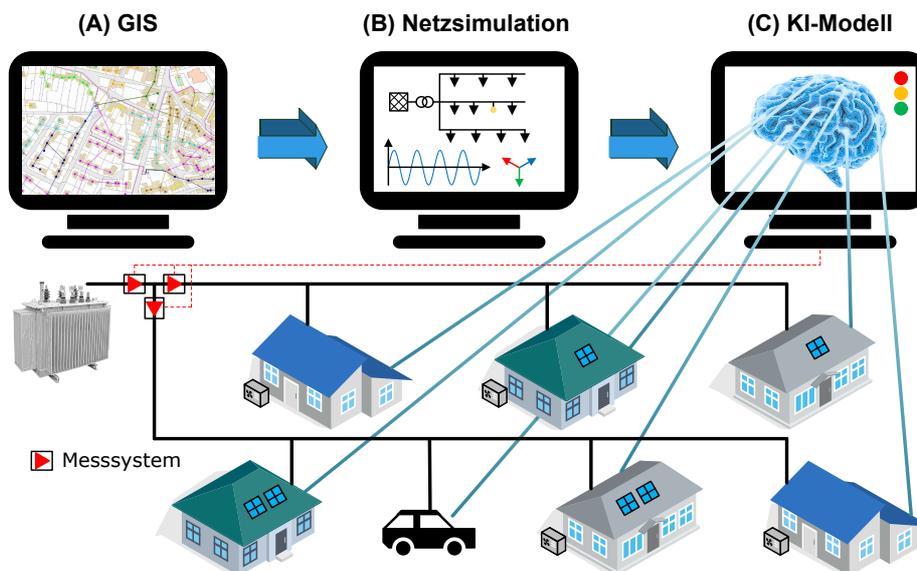


Abbildung 3: Gesamtsystem für das Monitoring in Niederspannungsnetzen

**(C) Framework für das Training neuronaler Netze:** Das KI-Framework trainiert nun mit den Trainingsdaten verschiedene künstliche neuronale Netze (KNN) in PyTorch [7] mit einer Auswahl geeigneter Hyperparametersätze. Für die KI-SE und die KI-LF werden jeweils zwei KI-Modelle trainiert. Ein KI-Modell approximiert dabei Spannungsbeträge und ein weiteres KI-Modell die Spannungswinkel. Als Eingabevariablen für die KI-SE dienen Abgangsmesswerte in der Ortsnetzstation und für die KI-LF Wirk- und Blindleistungswerte an allen Netzknoten.

### 3.1 Vorgehensweise für die KI-basierten Netzsimulation

Bei der Beschreibung der KI-basierten Netzsimulation werden zwei Anwendungsgebiete in der Stromversorgung näher betrachtet. Dazu zählen der Netzbetrieb und die Netzplanung, auch Netzausbauplanung genannt. Die Netzplanung dient der Erfüllung der Versorgungsaufgabe eines Netzbetreibers und beinhaltet prognostizierte Entwicklungen der Zukunft [8]. Ein elementares Werkzeug der Netzplanung ist die Lastflussberechnung mit dem Ziel sämtliche Knotenspannungen, Leiterströme, Leistungsflüsse, Netzverluste oder den Blindleistungsbedarf eines Stromnetzes bei unterschiedlichen Lastszenarien zu berechnen und mit den Vorgaben technischer Normen zu bewerten. Eine weitere Maßnahme zur Erfüllung der Versorgungsaufgabe ist die Netzbetriebsführung mit dem Ziel den aktuellen Netzzustand zu überwachen und bei kritischen Netzzuständen Handlungsmaßnahmen abzuleiten. Ein wesentliches Verfahren der Netzbetriebsführung ist die Netzzustandsschätzung, die mit Hilfe von gegebenen Eingangsdaten den aktuellen Netzzustand ermittelt. Sowohl die Netzzustandsschätzung als auch die Lastflussberechnung werden in dieser Arbeit im Rahmen der KI-basierten Netzsimulation umgesetzt und in einem realen Niederspannungsnetz validiert.

Das vorgestellte Verfahren lässt sich nach Abbildung 4 in eine Vorbereitungsphase (a), in eine Ausführungsphase für die KI-SE (b), z. B. für die Anwendung im Netzbetrieb und eine Ausführungsphase für die KI-LF (c), z. B. für die Anwendung in der Netzplanung unterteilen. Das Framework für die KI-basierte Netzsimulation führt in der Vorbereitungsphase die Generierung der Trainingsdaten, die Datenverarbeitung und das Training der KI-Modelle durch. Ein Fallgenerator generiert eine möglichst große Anzahl an Lastflussszenarien, die mit einer iterativen Lastflussberechnung analysiert und dessen Ergebnisse auf einer Datenbank gespeichert werden [2]. Im weiteren Verlauf dienen die vorliegenden Lastflussszenarien als Trainingsdaten für das KNN. Nach dem Training und der Validierung der KI-Systeme kann der Anwender die KI-SE und die KI-LF auf Recheneinheiten implementieren und im Ausführungsmodus für Aufgaben im Netzbetrieb und in der Netzplanung einsetzen.

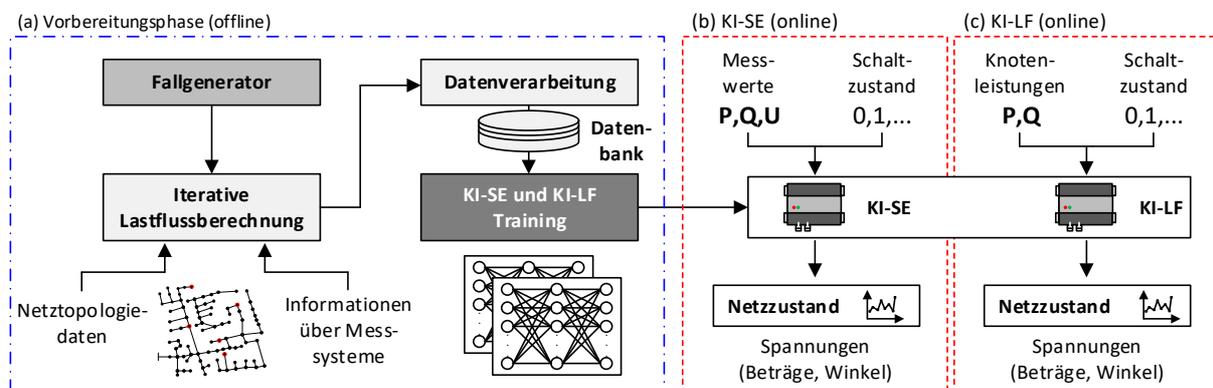


Abbildung 4: Struktur der KI-SE und der KI-LF [2], [3]

### 3.1.1 System Ein- und Ausgabedaten

Der Eingabevektor nach 3-1 für die KI-SE beinhaltet Messwerte (Wirkleistung  $P$ , Blindleistung  $Q$  und Spannungsbetrag  $|U|$ ) an allen überwachten Netzknoten  $J$  mit  $J \in \mathbb{N}$  und  $j \in \{1 \dots J\}$ , sowie den aktuellen Schaltzustand des Stromnetzes, codiert in der Variablen  $swt$ .

$$\mathbf{x}_{SE} = [\mathbf{p}_1 \quad \dots \quad \mathbf{p}_J \quad \mathbf{q}_1 \quad \dots \quad \mathbf{q}_J \quad \mathbf{u}_1 \quad \dots \quad \mathbf{u}_J \quad swt]^T$$

$$\text{mit } \mathbf{p}_j = [P_{j,L1} \quad P_{j,L2} \quad P_{j,L3}] ; \mathbf{q}_j = [Q_{j,L1} \quad Q_{j,L2} \quad Q_{j,L3}] ; \mathbf{u}_j = [U_{j,L1} \quad U_{j,L2} \quad U_{j,L3}] \text{ und } \quad 3-1$$

$$swt = [swt \quad 0 \quad 0]$$

Der Eingabevektor nach 3-2 für die KI-LF beinhaltet die Wirk- und Blindleistungen an allen Netzknoten  $G$  mit  $G \in \mathbb{N}$  und  $g \in \{1 \dots G\}$ , sowie den aktuellen Schaltzustand  $swt$ .

$$\mathbf{x}_{LF} = [\mathbf{p}_1 \quad \dots \quad \mathbf{p}_G \quad \mathbf{q}_1 \quad \dots \quad \mathbf{q}_G \quad swt]^T$$

$$\text{mit } \mathbf{p}_g = [P_{g,L1} \quad P_{g,L2} \quad P_{g,L3}] ; \mathbf{q}_g = [Q_{g,L1} \quad Q_{g,L2} \quad Q_{g,L3}] \text{ und } swt = [swt \quad 0 \quad 0] \quad 3-2$$

Die Beschreibung des Zustandes eines Stromnetzes kann mit vier voneinander unabhängigen Variablen erfolgen. Dazu zählen der Spannungsbetrag  $|U|$ , der Spannungswinkel  $\varphi$ , die Wirkleistung  $P$  und die Blindleistung  $Q$ . Zwei dieser Variablen müssen für jeden Netzknoten bekannt sein, um den Netzzustand vollständig zu berechnen. Somit ergibt sich der Ausgabevektor nach Gleichung 3-3 für die KI-LF mit den Spannungswinkeln und Spannungsbeträgen an allen Netzknoten  $G$  und für die KI-SE an allen nicht überwachten Netzknoten  $K$  mit  $K \in \mathbb{N}$ ,  $k \in \{1 \dots K\}$  und  $K = G - J$ .

$$\mathbf{y} = [\boldsymbol{\varphi}_1 \quad \dots \quad \boldsymbol{\varphi}_{K,G} \quad \mathbf{u}_1 \quad \dots \quad \mathbf{u}_{K,G}]^T$$

$$\text{mit } \mathbf{u}_{(k,g)} = [U_{(k,g),L1} \quad U_{(k,g),L2} \quad U_{(k,g),L3}] \text{ und } \boldsymbol{\varphi}_{(k,g)} = [\varphi_{(k,g),L1} \quad \varphi_{(k,g),L2} \quad \varphi_{(k,g),L3}] \quad 3-3$$

### 3.1.2 Generierung der Trainingsdaten

Der erste Schritt in der Vorbereitungsphase ist die Generierung der Trainingsdaten. Ein Fall-generator generiert eine große Anzahl relevanter Lastflussszenarien [2]. Die Szenariendefinition unterscheidet Verbraucherlasten, PV-Anlagen und Elektrofahrzeuge. Als Grundlage für die Szenariendefinition dienen Standard-Lastprofile für die Verbraucherlasten (inklusive temperaturabhängiger Leistungsprofile für Wärmepumpen), gemittelte Einspeiseprofile für PV-Anlagen und gemittelte Ladeprofile für Elektrofahrzeuge.

1. Aufbau des Stromnetzmodells in der Netzsimulation und Zuordnung der Last- und Einspeiseprofile zu den Verbrauchern und Einspeiseanlagen
2. Skalierung der gemittelten Leistungsprofile zur Berücksichtigung von Last- und Erzeugungsspitzen
3. Gaußverteiltes Verrauschen der Leistungsprofile zur Vermeidung von Überanpassung der KNN und zur Steigerung der Variabilität zwischen Verbrauchern und Einspeiseanlagen gleichen Typs und gleicher Nennleistung

Im Rahmen dieser Arbeit wurden Datensätze von 17280 Szenarien für die KI-LF und 51840 Szenarien für die KI-SE generiert. Die Trainingsdaten, also die Daten, die für das Training der KI-Modelle eingesetzt werden, inklusive Validierungsdaten, umfassen in der Regel 80 % der Gesamtdaten [9]. Die restlichen Daten dienen zur Überprüfung der trainierten Modelle. Der Testdatensatz für die KI-LF besteht aus 4320 und für die KI-SE aus 12960 Szenarien.

### 3.1.3 Definition der KNN-Modelle

Als KNN wird die Gesamtheit vieler künstlicher Neuronen und deren Verbindung miteinander bezeichnet. Abbildung 5 zeigt die Struktur eines KNN mit einer Eingabeschicht  $x$ , einer Ausgabeschicht  $y$  und  $v$  verdeckten Schichten  $h_v$  mit jeweils  $M_v$  Neuronen.

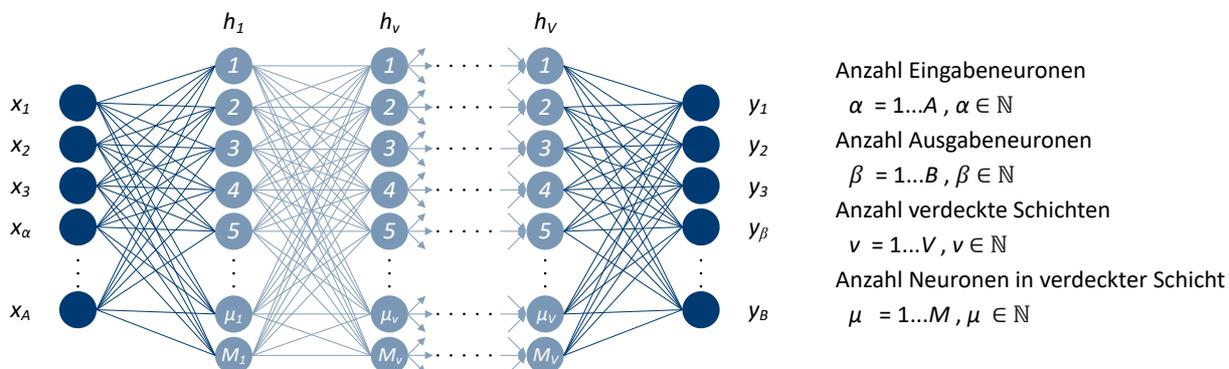


Abbildung 5: Künstlich neuronales Netz

Wird die Anzahl der verdeckten Neuronen in jeder verdeckten Schicht als konstant angenommen, so lässt sich die Anzahl  $M_1 = M_v = M_V$  der künstlichen Neuronen in den verdeckten Schichten nach 3-4 aus der Anzahl der Ein- und Ausgabeneuronen,  $A$  und  $B$  abschätzen [10].

$$M = \frac{2}{3} \cdot A + B \quad 3-4$$

Im Trainingsmodus ist die Topologie des neuronalen Netzes fest vorgegeben. Trainiert wird das KNN durch die Anpassung der Gewichtungen und Grundgewichte der einzelnen Neuronen mit Hilfe von Optimierungsalgorithmen, wie beispielsweise die Hebb-Lernregel, Backpropagation-Lernregel oder der Adam-Algorithmus.

## 4 Simulationen und Ergebnisse

Das Kapitel 4 zeigt die Durchführung der KI-basierten Netzsimulation in einem realen Stromnetz. Die relativen Fehler der berechneten Spannungsbeträge sowie die absoluten Fehler der Spannungswinkel nach Gleichung 4-1 sind dabei ein Maß für die Genauigkeit der KI-Modelle.

$$e_U = \frac{U_{KI-LF/SE} - U_{wahr}}{U_n / \sqrt{3}} \text{ und } E_\varphi = \varphi_{KI-LF/SE} - \varphi_{wahr} ; \text{ wahr: Messungen/Testdaten} \quad 4-1$$

### 4.1 Training und Validierung der KI-Modelle

Vor dem Training der KNN müssen zunächst verschiedene Parameter, sogenannte Hyperparameter, ausgewählt und definiert werden. Die Hyperparameter sind vor dem Training manuell festzulegen und lassen sich im Lernalgorithmus nur eingeschränkt anpassen. Zu den Hyperparametern gehören u. a. die Lernrate  $lr$ , die Anzahl der verdeckten Schichten  $V$ , die Anzahl der Neuronen in den verdeckten Schichten  $M$ , die Batch Größe  $bs$  sowie die Aktivierungsfunktion  $\phi$ . Zwei verbreitete Aktivierungsfunktionen sind die ReLU (engl. Rectified Linear Unit) und die sigmoid Funktion. Die Auswahl der Hyperparameter basiert im ersten Schritt auf den Erfahrungen des Entwicklers oder kann anhand bereits publizierter KNN Architekturen, die ähnliche Problemstellungen behandeln, abgeleitet werden. Tabelle 1 zeigt eine Auswahl möglicher

KNN Architekturen mit den zugehörigen Hyperparameterkonfigurationen, die im Rahmen dieser Arbeit untersucht und mit dem Adam-Algorithmus trainiert wurden.

Tabelle 1: Untersuchte Hyperparameter Konfigurationen

ID	KI-LF				KI-SE			
	$M$	$V$	$bs$	$\phi$	$M$	$V$	$bs$	$\phi$
1	2683	3	10	ReLU	20	3	10	ReLU
2	4600	4	10	ReLU	40	4	10	ReLU
3	2683	2	10	ReLU	20	2	10	ReLU
4	2683	2	128	ReLU	20	2	128	ReLU
5	2683	3	128	ReLU	20	3	128	ReLU
6	2683	4	128	ReLU	20	4	128	ReLU
7	2683	4	64	ReLU	20	4	64	ReLU
8	2683	4	64	sigmoid	20	4	64	sigmoid
9	2683	4	32	sigmoid	20	4	32	sigmoid

Abbildung 6 beinhaltet die Testfehler der KNN mit  $ID = 1 \dots 9$  für die KI-LF und KI-SE. Es ist zu erkennen, dass die KNN Modelle bei unterschiedlichen Hyperparameterkonfigurationen eine unterschiedliche Performance zeigen. Das Modell, welches bei Anwendung auf den Testdatensatz den kleinsten Fehler verursacht, kommt in der Ausführungsphase zum Einsatz.

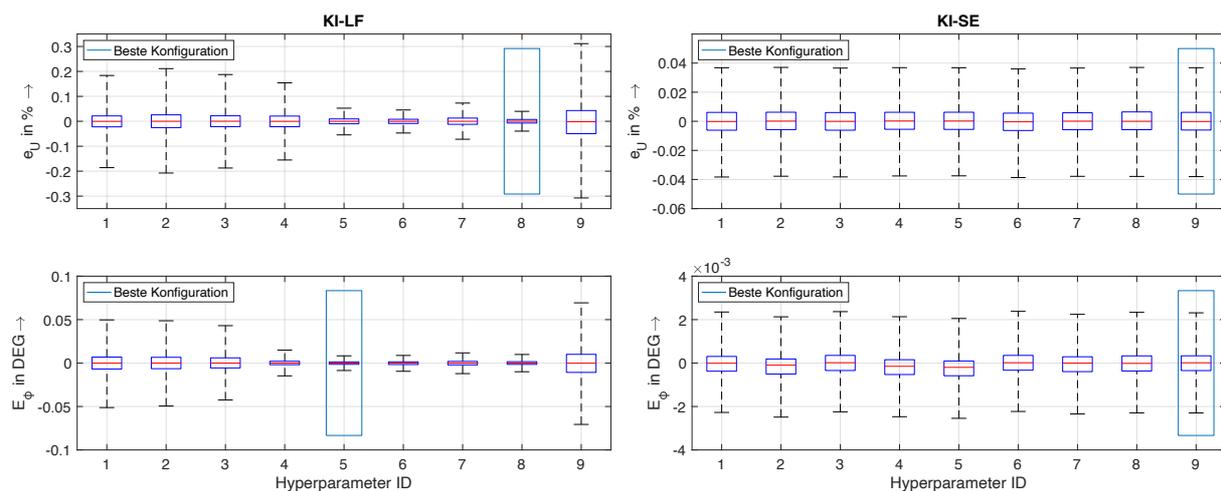


Abbildung 6: Ergebnisse der Hyperparameteroptimierung (Boxplots: 95 % Quantil)

## 4.2 Ausführungsphase – Monitoring in einem realen Niederspannungsnetz

Das Kapitel 4.2 zeigt die Ergebnisse der Ausführungsphase für die KI-SE im Abschnitt 4.2.1 und für die KI-LF im Abschnitt 4.2.2.

### 4.2.1 KI-basierte Netzzustandsschätzung (KI-SE)

Das KI-Modell mit der Hyperparameterkonfiguration ID 9 nach Tabelle 1, welches bei der Anwendung auf die Testdaten die beste Genauigkeit zeigt, wird im Kapitel 4.2.1 mit realen Messdaten validiert. Die zur Verfügung stehenden Messungen erstrecken sich über einen Zeitraum von sechs Tagen und liefern Ergebnisse aus 10-Minuten-Mittelwerten. Die Messwerterfassung erfolgte an drei Netzknoten (siehe Abbildung 2). Zwei dieser Messungen dienen als Referenzmessungen und bleiben für das Verfahren der KI-SE unbekannt. Da in der Ortsnetzstation nur ein Abgang überwacht wurde und keine weiteren Messungen aus dem restlichen Stromnetz

(siehe Abbildung 2) vorliegen und somit auch nicht beim Training der KNN berücksichtigt wurden, muss die gemessene Spannung vor Ausführung der KI-SE korrigiert werden. Die Spannungsdifferenz, die sich durch zusätzliche Lasten oder Einspeiseanlagen im restlichen Stromnetz ergibt, wird vor Anwendung der KI-SE von der gemessenen Spannung subtrahiert und zu den von der KI-SE geschätzten Spannungen innerhalb des Abgangs hinzuaddiert. Dieses Vorgehen ist zulässig, da sich eine geringfügige Spannungsänderung an der Sammelschiene in der Ortsnetzstation näherungsweise linear auf alle nachgelagerten Netzknoten auswirkt [11]. Mit Hilfe weiterer Simulationen konnte dies auch für das untersuchte Stromnetz bestätigt werden. Sind alle Abgänge einer Ortsnetzstation überwacht, ist eine solche Korrektur nicht erforderlich. Abbildung 7 und Abbildung 8 zeigen die Ergebnisse der KI-SE für die Knoten 16 und 11, exemplarisch für den Leiter L1. Die relativen Fehler der geschätzten Leiter-Erd-Spannungen sind für 95 % der ausgewerteten Daten am Knoten K16 kleiner 0,8369 % und am Knoten K11 kleiner 1,0574 %.

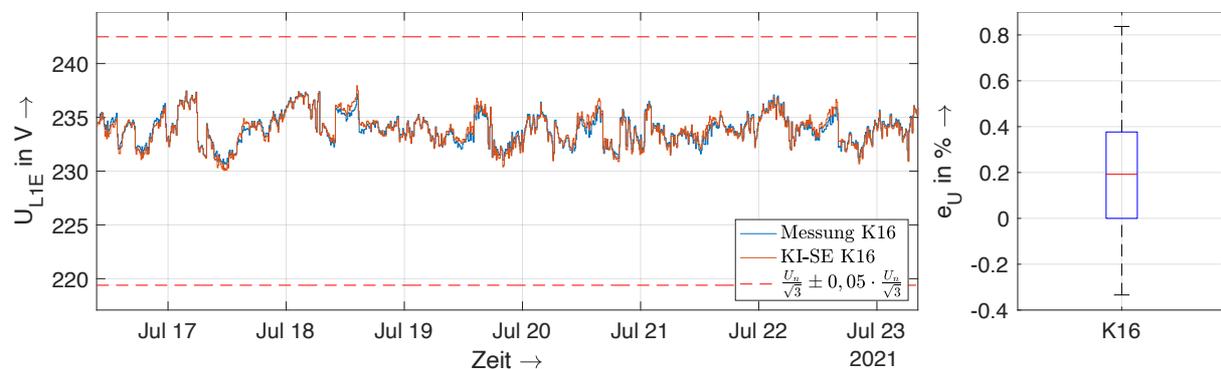


Abbildung 7: Ergebnisse der KI-SE für den Knoten 16 (K16) (Boxplot: 95 % Quantil)

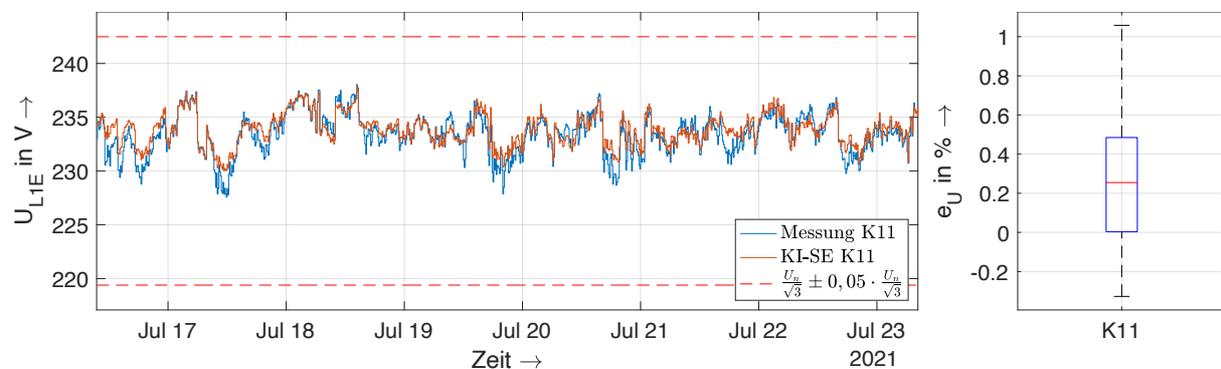


Abbildung 8: Ergebnisse der KI-SE für den Knoten 11 (K11) (Boxplot: 95 % Quantil)

#### 4.2.2 KI-basierte Lastflussberechnung (KI-LF)

Das Kapitel 4.2.2 beinhaltet die Ergebnisse der KI-LF. Zunächst erfolgt die Überprüfung der Rechengenauigkeit der KI-LF bei der Berechnung der Testszenarien nach Kapitel 3.1.2, exemplarisch für den Netzabschnitt nach Abbildung 2. Anschließend werden die Rechenzeiten für die Durchführung einer einzelnen Lastflussberechnung und für die Durchführung einer Jahresrechnung, bestehend aus 35040 15min-Mittelwerten, ausgewertet und mit anderen Lastflussberechnungsverfahren gegenübergestellt. Abbildung 9 zeigt die Ergebnisse der KI-LF für die Leiter-Erd-Spannung  $U_{L1E}$  und den Spannungswinkel  $\varphi_{L1E}$ . Für 95 % der Testfälle ist  $|e_U|$  stets kleiner als 0,0491 % und  $|E_\varphi|$  stets kleiner als 0,0128°. Die Ergebnisse verdeutlichen, dass die KI-LF den vollständigen Netzzustand mit hoher Genauigkeit berechnet.

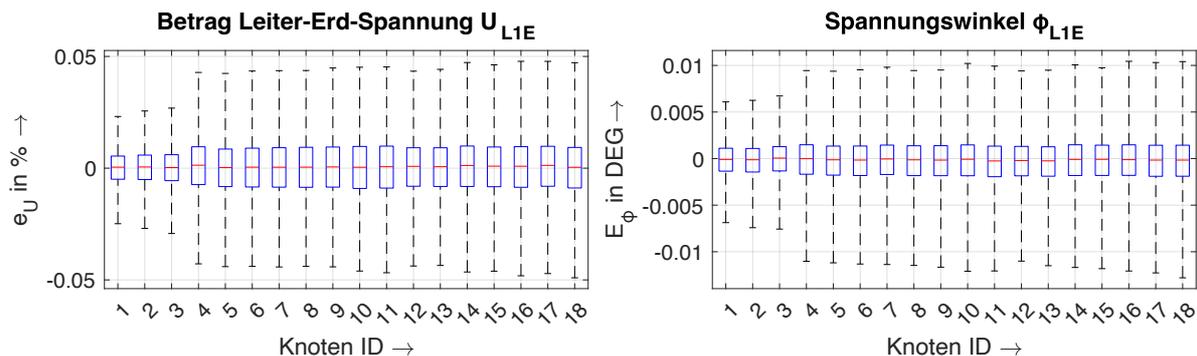


Abbildung 9: Ergebnisse der KI-LF für den Abgang nach Abbildung 2 (Boxplots: 95 % Quantil)

Die benötigte Rechenzeit für eine Lastflussberechnung nach Tabelle 2 ergibt sich aus der gemittelten Rechenzeit für 864 nacheinander durchgeführte Berechnungen (9 Tage in 15 min Intervallen – basierend auf Standard-Lastprofilen). Es ist festzustellen, dass die KI-LF für die Berechnung von 35040 Lastflussszenarien ca. 4080-mal schneller ist als die Berechnung mit dem anwenderorientierten Netzberechnungsprogramm ATPDesigner. Es ist zu beachten, dass ATPDesigner sowohl eine Visualisierungs- und Berichtskomponente als auch eine Vielzahl an Analysemethoden zur Bewertung der Lastflussergebnisse enthält. Bei der Anwendung der KI-LF sind zusätzlich noch die Rechenzeiten für die Generierung der Trainingsdaten und die Analyse der Rechenergebnisse zu berücksichtigen. Da die Generierung der Trainingsdaten jedoch offline erfolgt, spielt sie im Onlinebetrieb keine Rolle.

Tabelle 2: Rechenzeiten der Lastflussberechnungen (CPU: Intel Core i5-6200U, 2,3 GHz ; RAM: 8GB)

Anzahl	Rechenzeiten	
	ATPDesigner	KI-LF
1	5,9 s	0,036 s
35040	57,43 h ( $\approx$ 2,4 d)	50,67 s ( $\approx$ 0,014 h)

## 5 Zusammenfassung und Ausblick

Die Validierung der KI-basierten Netzsimulation erfolgt in einem realen Niederspannungsnetz. Die KI-Modelle schätzen basierend auf einer Abgangsmessung in einer Ortsnetzstation als Inputgrößen die elektrischen Variablen des überwachten Abgangs, sodass der geschätzte Netzzustand vollständig vorliegt. Ein weiteres KI-Modell bietet die Möglichkeit, die Lastflüsse im betrachteten Netzgebiet zu berechnen und z. B. Handlungsempfehlungen bei kritischen Netzzuständen zu validieren. Die daten- und rechenintensive Trainingsphase erfolgt offline, wohingegen im Onlinebetrieb die KI-basierten Systeme die Ergebnisse sehr schnell und robust gegenüber fehlenden Messdaten liefern. Die KI-Modelle lernen in der Trainingsphase die komplexen Zusammenhänge und Muster in den Trainingsdaten und können im Onlinebetrieb den Netzzustand auch bei geringer Anzahl an Messsystemen schätzen. Die KI-basierte Berechnung der Lastflüsse erfolgt im operativen Betrieb mit geringer Rechenzeit unabhängig von der Anzahl der Netzknoten. Um die Schätzgenauigkeit des Verfahrens zu überprüfen, werden die Ergebnisse der KI-basierten Netzsimulation mit Referenzmessungen, die sich innerhalb des Abgangs befinden, verglichen. Die Untersuchungen zeigen, dass KNN in der Lage sind, Netzzustände mit wenigen Eingangswerten zu schätzen und Lastflussberechnungen in großen Niederspannungsnetzen mit vielen Betriebsmitteln im operativen Betrieb, d. h. mit geringen Rechenzeiten, durchzuführen.

## 6 Danksagung

Diese Veröffentlichung basiert auf Erkenntnissen aus dem Projekt „Grid-Analysis – KI-basierte Systemanalyse im Normal und Kurzschlussbetrieb“ [12], welches durch das deutsche Bundesministerium für Wirtschaft und Klimaschutz (BMWK) im Rahmen der Fördermaßnahme „Innovationen für die Energiewende“ gefördert wird. (Förderkennzeichen: 03EI6034A)

Gefördert durch:



Bundesministerium  
für Wirtschaft  
und Klimaschutz

aufgrund eines Beschlusses  
des Deutschen Bundestages

## 7 Literaturverzeichnis

- [1] „ATPDesigner“. <http://atpdesigner.de/> (zugegriffen 5. Oktober 2021).
- [2] A. Winter, M. Igel, und P. Schegner, „Application of artificial intelligence in power grid state analysis and -diagnosis“, in *NEIS 2020. Conference on Sustainable Energy Supply and Energy Storage Systems*, Hamburg, 15.09 2020, S. 128–133.
- [3] A. Winter, M. Igel, und P. Schegner, „Supervised Learning Approach for State Estimation in Distribution Systems with missing Input Data“, in *2021 IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe)*, Espoo, Finland, Okt. 2021, S. 1–5. doi: 10.1109/ISGTEurope52324.2021.9639949.
- [4] A. Winter u. a., „KI-basierte Systemanalyse im Normal- und Kurzschlussbetrieb“, *Magazin für die Energiewirtschaft*, Nr. 12, 2021.
- [5] Bundesnetzagentur und Bundeskartellamt, „Monitoringbericht 2020“, Bonn, 2020.
- [6] B. Brandherm, M. Deru, A. Ndiaye, G.-L. Kiefer, J. Baus, und R. Gampfer, „Integration erneuerbarer Energien – KI-basierte Vorhersageverfahren zur Stromerzeugung durch Photovoltaikanlagen“, in *Data Science anwenden*, T. Barton und C. Müller, Hrsg. Wiesbaden: Springer Fachmedien Wiesbaden, 2021, S. 147–170. doi: 10.1007/978-3-658-33813-8\_9.
- [7] A. Paszke u. a., „PyTorch: An Imperative Style, High-Performance Deep Learning Library“, gehalten auf der 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), Vancouver, Canada.
- [8] K. F. Schäfer, *Netzberechnung: Verfahren zur Berechnung elektrischer Energieversorgungsnetze*. Wiesbaden [Heidelberg]: Springer Vieweg, 2020.
- [9] M. Deru, A. Ndiaye, und Galileo Press, *Deep Learning mit TensorFlow, Keras und TensorFlow.js Einstieg, Konzepte und KI-Projekte mit Python, JavaScript und HTML5. Aktuell zu TensorFlow 2.0*. 2020.
- [10] J. Heaton, *Introduction to neural networks with Java*, 2. ed., 1. print. St. Louis, Mo: Heaton Research, 2008.
- [11] S. Raczka, D. Hilbrich, A. Bruggemann, und C. Rehtanz, „A Model Predictive Control Algorithm for large-scale Integration of Electromobility“, in *2020 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*, The Hague, Netherlands, Okt. 2020, S. 690–694. doi: 10.1109/ISGT-Europe47291.2020.9248960.
- [12] „GridAnalysis – KI-basierte Systemanalyse von Stromverteilnetzen im Normal- und Kurzschlussbetrieb“. <http://gridanalysis.de/> (zugegriffen 7. Oktober 2021).