

Konzept, Prototyp und erste Erfahrungen einer KI-basierten Erdschlussortung mit stationären Messgrößen in Verteilungsnetzen

Andreas Winter, energis-Netzgesellschaft mbH, 66121 Saarbrücken, Deutschland

Michael Igel, Hochschule für Technik und Wirtschaft des Saarlandes, 66117 Saarbrücken

andreas.winter@energis-netzgesellschaft.de, michael.igel@htwsaar.de

Kurzfassung

Im Rahmen der Energiewende steigt der Anteil elektrischer Energie durch PV- und Windkraftanlagen stetig an. Die Stromerzeugung erfolgt zunehmend dezentral in der Verteilnetzebene bei Reduktion zentraler Großkraftwerke. Neben dem steigenden Ausbau erneuerbarer Energien ist zukünftig auch eine zunehmende Elektrifizierung der Mobilität und Wärmeversorgung zu erwarten. Dies führt dazu, dass Netzbetreiber Stromverteilungsnetze sukzessive ausbauen, um deren Stromtragfähigkeit zu erhöhen. Durch den Anstieg der Verkabelung werden sich Anforderungen an die Erdschlusserfassung und -ortung weiter erhöhen. Der vorliegende Beitrag stellt ein Verfahren vor, das künstliche Intelligenz als datenbasierter Ansatz für die Erfassung und Ortung von Erdschlüssen in isoliert und kompensiert betriebenen Stromverteilungsnetzen verwendet. Das KI-basierte Verfahren verwendet stationäre Größen. Die Anwendung des Verfahrens und die Darstellung der Ergebnisse erfolgen zunächst in einem einfachen synthetischen 20-kV-Kabelnetz mit strahlenförmiger Netztopologie. Danach wird das KI-basierte Verfahren in einem Mittelspannungsnetz mit strahlenförmigen und ringförmigen Strukturen eingesetzt. Die Untersuchungen zeigen, dass die KI-basierte Erdschlusserfassung und -ortung mit stationären Größen zuverlässig arbeitet und sich durch eine hohe Genauigkeit, geringe Rechenzeiten und damit kurze Reaktionszeiten auszeichnet. Das KI-basierte Verfahren eröffnet ein weites Feld neuartiger datengetriebener Verfahren zur Erdschlusserfassung und -ortung als Erweiterung der bekannten mathematisch-algorithmischen Verfahren.

Abstract

As part of the energy transition, the share of decentralized electricity generation from PV and wind power is increasing. At the same time, electrification of mobility and heating is progressing. As a result, distribution system operators need to expand distribution power grids to increase their capacity. With more underground cabling and decentralized generation, the requirements for earth fault detection and protection are also rising. This paper presents an AI-based method for detecting and locating earth faults in isolated and compensated distribution power grids. It uses stationary quantities in the natural system (L123) and the symmetrical component system (012). The method is first applied to a synthetic 20-kV-radial cable power grid and then tested in a medium-voltage power grid with both radial and ring structures. Results show that the AI-based method works reliably with high accuracy and low computation time, offering a promising complement to traditional algorithmic approaches.

1 Einleitung

Die steigende Anzahl dezentraler Erzeugungsanlagen und der damit einhergehende Netzausbau stellen die Verteilnetzbetreiber vor große Herausforderungen. In den Stromverteilungsnetzen werden Freileitungen zunehmend durch Kabel ersetzt, neue Leitungstrassen im Mittelspannungsnetz werden fast ausschließlich, im Hochspannungsnetz zu einem großen Anteil mit Kabelsystemen realisiert [2]. In den Stromverteilungsnetzen der Hoch- und Mittelspannung dominiert die kompensierte Sternpunktbehandlung mit Resonanzsternpunkterdung (RESPE). In Mittelspannungsnetzen geringerer Ausdehnung wird auch die isolierte Sternpunktbehandlung (OSPE) eingesetzt.

Die Sternpunktbehandlung hat einen unmittelbaren Einfluss auf die im Falle von Leiter-Erd-Fehlern fließenden Fehlerströme. Statistiken zeigen, dass der 1-polige Erdfehler eine der häufigsten Fehlerarten ist. Aufgrund der stationären und insbesondere transienten Überspannungen steigt in Stromnetzen mit Resonanzsternpunkterdung (RESPE) und isolierter Sternpunktbehandlung (OSPE) im

Erdschlussfall die Gefahr, dass sich der Erdschluss zu einem Doppelerdkurzschluss ausweitet und durch den selektiven Kurzschlusschutz abgeschaltet werden muss. Für die Gewährleistung einer sicheren und zuverlässigen Stromversorgung ist es daher notwendig, den erdschlussbetroffenen Leitungsabgang schnell und selektiv zu erfassen und den Erdschlussort zu lokalisieren [8]. Der Beitrag stellt ein KI-basiertes Verfahren (KI-EsEO) zur Erdschlusserfassung und -ortung vor, das mit Hilfe von stationären, netzfrequenten Größen im natürlichen System L123 arbeitet.

1.1 Verfahren zur Erdschlussortung

Klassische mathematisch-algorithmische Verfahren zur Erdschlusserfassung und -ortung lassen sich in stationäre und transiente Verfahren unterteilen. Die stationären Verfahren analysieren Effektivwerte und Phasenwinkel der Ströme und Spannungen, d. h. deren komplexe netzfrequente Zeiger vorzugsweise im Nullsystem, wohingegen die transienten Verfahren i. A. den zeitlichen Verlauf der Aufladeschwingung nach Erdschlusseintritt auch vorzugsweise im Nullsystem auswerten. Daraus folgend können KI-basierte Verfahren zur Erdschlusserfassung und -ortung

ebenfalls in stationäre und transiente Verfahren unterteilt werden.

- KI-EsEO-TR: Transiente KI-basierte Verfahren zur Erdschlusserfassung und -ortung verwenden als Trainingsdaten und als Messwerte im operativen Betrieb i. a. R. den zeitlichen Verlauf der Aufladeschwingung.
- KI-EsEO-ST: Stationäre KI-basierte Verfahren zur Erdschlusserfassung und -ortung verwenden als Trainingsdaten und als Messwerte im operativen Betrieb die komplexen netzfrequenten Zeiger.

Ein weit verbreitetes mathematisch-algorithmisches Verfahren zur Erdschlusserfassung und -ortung in strahlenförmigen Stromverteilungsnetzen mit Resonanzsternpunktterdung (RESPE) ist die Wattmetrische Erdschlusserfassung und -ortung ($\cos(\varphi)$ -Verfahren). Das Verfahren verwendet als Messwerte die netzfrequenten Zeiger von Nullspannung \underline{U}_0 und Nullstrom \underline{I}_0 , die typischerweise am Leitungsabgang in der Unterstation gemessen werden. In Stromverteilungsnetzen mit isolierter Sternpunktbehandlung (OSPE) werden von dem $\sin(\varphi)$ -Verfahren als Messwerte ebenfalls die netzfrequenten Zeiger von Nullspannung \underline{U}_0 und Nullstrom \underline{I}_0 verwendet.

Die stationäre KI-basierte Erdschlusserfassung und -ortung KI-EsEO-ST wurde daher so konzipiert, dass netzfrequente Zeiger als Messwerte verwendet werden können. Damit ist eine Systemkompatibilität zu den klassischen mathematisch-algorithmischen Verfahren sichergestellt. Das Konzept der KI-EsEO-ST wurde mit einem Künstlichen Neuronalen Netz (KNN) als Prototyp implementiert und im Labor mit Hilfe eines Netzberechnungsprogramms validiert.

1.2 Transiente KI-basierte Erdschlussortung

Im Rahmen der Fachtagung STE 2022 präsentierten die Autoren ein Verfahren zur transienten KI-basierten Erdschlussortung (KI-EsEO-TR), das mit Hilfe Künstlicher Neuronaler Netze (KNN) und Convolutional Neural Networks (CNN) [3] transiente Erdschlussvorgänge analysiert, um einen Erdschluss in einem strahlenförmigen Mittelspannungsnetz mit Resonanzsternpunktterdung (RESPE) zu orten [2]. Die Berechnung der sehr hohen Anzahl transienter Erdschlussvorgänge mit Hilfe eines Netzberechnungsprogramms sowie deren Aufbereitung zum Training der KNN/CNN hat sich als komplexer und zeitintensiver Prozess herausgestellt. Daher wurde das Konzept einer KI-basierten Erdschlusserfassung und -ortung mit stationären Größen (KI-EsEO-ST) entwickelt und im Labor erste Untersuchungen durchgeführt. Ziel war es zu untersuchen, ob eine KI-basierte Erdschlussortung durch KNN mit stationären Größen möglich ist und zuverlässig arbeitet.

1.3 Grundlagen der Künstlichen Intelligenz

Die Künstliche Intelligenz (KI) als Teilgebiet der Informatik gewinnt zunehmend an Bedeutung und ist zu einer wesentlichen Technologie avanciert. Als Bestandteile der KI verfolgen Machine Learning und darüber hinaus das Deep Learning das Ziel neue Algorithmen (Modelle) zu finden, die auf Basis von vorgegebenen und aufbereiteten Daten Entscheidungen und Bewertungen liefern können. Der gesamte Prozess bei Deep Learning hängt primär von Qualität und Menge der Trainingsdaten ab und erfordert hohe Rechenleistungen, um eine hohe Genauigkeit und Performance des Trainings zu erzielen. KI-basierte Modelle erweitern damit die bekannten mathematisch-algorithmischen um neuartige datengetriebene Verfahren.

Verfahren der KI lernen in der Trainingsphase komplexe Muster und setzen diese Fähigkeiten nach Abschluss des Trainings im operativen Betrieb hoch performant um. Anforderungen an die benötigte Hardware im Betrieb sind eher gering einzuschätzen. Das Verfahren der stationären KI-basierten Erdschlusserfassung und -ortung KI-EsEO-ST verwendet ein klassisches Netzberechnungsprogramm zur Berechnung stationärer Erdschlüsse in isoliert und kompensiert betriebenen Stromverteilungsnetzen, um die zum Training der KI-Modelle benötigt Trainingsdaten in großer Anzahl bereitzustellen.

1.3.1 Künstliche Neuronale Netze

Künstliche Neuronale Netze (KNN) sind rechnergestützte Modelle, die sich an der Struktur des menschlichen Gehirns orientieren. Sie bestehen aus miteinander verbundenen „Neuronen“ und können durch Training Muster in Daten erkennen. KNN werden in vielen Bereichen eingesetzt, etwa bei der Bild- und Spracherkennung oder in der medizinischen Diagnostik [3].

Dank ihrer Fähigkeit, auch komplexe Muster in Daten zu erkennen, bieten Künstliche Neuronale Netze im Bereich der Erdschlusserfassung neue Ansätze. So kann die KI durch Training charakteristische Merkmale stationärer Größen – wie etwa Betrag und Phasenwinkel der komplexen Zeiger von Leiter-Erd-Spannungen oder Leiterströmen bei stehendem Erdschluss – identifizieren. Dies ermöglicht eine präzisere Detektion im Vergleich zu mathematisch-algorithmischen Verfahren. Die Leistungsfähigkeit dieser KI-basierten Methoden hängt dabei maßgeblich von der Qualität der Trainingsdaten ab, die wiederum auf den Ergebnissen konventioneller Netzberechnungen basieren [3].

2 Stationäre KI-basierte Erdschlussortung

Die Berechnung stationärer Erdschlussgrößen, insbesondere im Nullsystem, stellt keine besonderen Anforderungen an Hard- oder Software von Netzberechnungsprogrammen. Durch standardisierte Digitalisierungsprozesse kann in angemessener Zeit eine große Anzahl stationärer Erdschlusszenarien simuliert werden. Die resultierenden Messgrößen werden über ein Kommunikationsnetzwerk in

einer SQL-Datenbank auf einem zentralen Datenserver gespeichert. Die Aufbereitung dieser Messdaten zu Trainingsdaten für Künstliche Neuronale Netze sowie der anschließende Trainingsprozess lassen sich beispielsweise mit der Skriptsprache Python nahezu vollständig automatisieren. Kapitel 2 beschreibt die Entwicklung der KI-basierten Erdschlusserfassung mit stationären Größen (KI-EsEO-ST) – beginnend mit der Simulationsumgebung, über die Definition der Ein- und Ausgabegrößen, bis hin zur Generierung der Trainingsdaten.

2.1 Simulationsumgebung

Das Framework der KI-EsEO-ST besteht aus drei Teilsystemen. Bild 1 zeigt die strukturelle Darstellung der Methodik. Im ersten Schritt (A) findet die synthetische Generierung der Trainingsdaten, im zweiten Schritt (B) das Training der KI-Systeme und im dritten Schritt (C) die Ausführung der Fehlerklassifikation statt. Die für das Training erforderlichen Daten liefert dabei ein klassisches Netzrechnungsprogramm zur Berechnung transienter Ausgleichsvorgänge und stationärer Netzzustände (ATPDesigner/ATP [1]). Ein Fallgenerator erzeugt eine große Anzahl möglicher Fehlerfälle unter Berücksichtigung verschiedener Fehlerintrittsbedingungen z. B. einem Fehlerübergangswiderstand. Das Modell des Stromverteilungsnetzes im Netzrechnungsprogramm berechnet die generierten Erdschlussfälle und speichert die Ergebnisse in einer SQL-Datenbank.

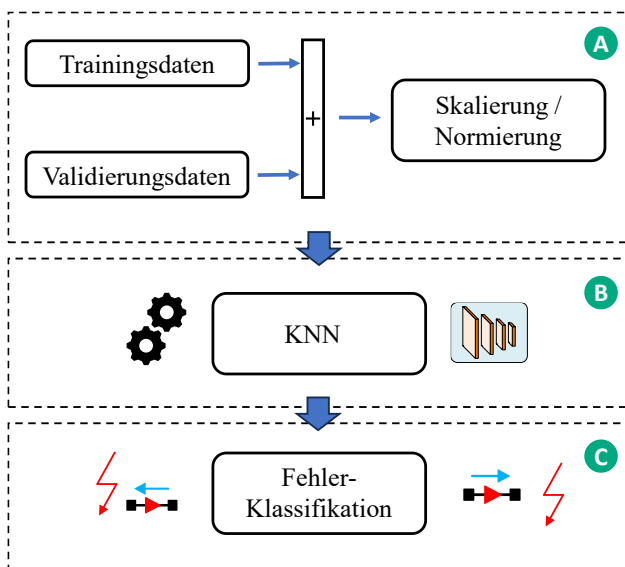


Bild 1 Simulationsumgebung der KI-EsEO-ST

Das Training der KNN erfolgt in der Programmiersprache Python unter Verwendung der Deep-Learning-Bibliothek PyTorch [4]. PyTorch bietet eine flexible und leistungsfähige Umgebung zur Modellierung, dem Training und der Evaluierung neuronaler Netze. Die Trainingsdaten stammen aus vorherigen Netzrechnungen und werden in geeigneter Form aufbereitet, um ein effizientes und zielgerichtetes Lernen der relevanten Merkmale zu ermöglichen [6]. Das Ergebnis des Trainingsprozesses ist eine Koeffizientenmatrix, die wie in der Netzschutztechnik für mathematisch-algorithmische Schutzfunktionen üblich Teil

einer nicht veränderlichen und damit typprüfbarer Software ist. Die Qualität des trainierten KNN kann mit Performancedaten bewertet werden, die als weiteres Ergebnis des Trainingsprozesses verfügbar sind.

2.2 Generierung der Trainingsdaten

Mit Hilfe eines Netzberechnungsprogramms wurden in Mittelspannungsverteilungsnetzen stationäre Erdschlüsse simuliert. Der Fehlerort wurde entlang jeder Leitung beginnend am Leitungsanfang (0 % Fehlerort) bis zum Leitungsende (100 % Fehlerort) mit einer Schrittweite von 0,1 % variiert. Als weitere Varianz wurde der Übergangswiderstand am Fehlerort von 0Ω bis 10Ω mit einer Schrittweite von 5Ω verändert. Damit ergeben sich pro Leitung ca. 3.000 Erdschlussimulationen. Nach jeder Erdschlussimulation werden die stationären Zeiger der Leiter-Erd-Spannungen \underline{U}_{L123} , der Leiterströme \underline{I}_{L123} , Nullspannung \underline{U}_0 , Nullstrom \underline{I}_0 , Übergangswiderstand R_F und der Fehlerort in der SQL-Datenbank gespeichert. Aus den Daten der SQL-Datenbank wurden mit Hilfe der Skriptsprache Python die Trainingsdaten für das KNN generiert. Die Trainingsdaten werden in Trainingsfälle und Validierungsdaten unterteilt: 80 % Trainingsfälle zum Training des KNN und 20 % Validierungsdaten zur Validierung des trainierten KNN. Die Aufteilung in Trainingsfälle und Validierungsdaten erfolgt mit Hilfe von Zufalls-generatoren.

Die Trainingsdaten können durch weitere Netzrechnungen ergänzt werden, die z. B. kapazitive Unsymmetrien von Freileitungsnetze oder Änderungen des Verstim-mungsgrades von Erdschlusslöschspulen bedingt durch Spulenresonanzregler berücksichtigen. Nach einem erneuten Training werden die neuen Erdschlussmerkmale von dem KNN für die Erdschlusserfassung und -ortung berücksichtigt.

2.3 Ein- und Ausgangsgrößen

Als Eingangsgrößen für die KI-EsEO-ST dienen die komplexen Zeiger der Leiter-Erd-Spannungen \underline{U}_{L123} sowie der Leiterströme \underline{I}_{L123} (Bild 2). Diese Größen werden von den Schutzsystemen im Umspannwerk kontinuierlich erfasst und in geeigneter Form gespeichert.



Bild 2 Ein- und Ausgangsgrößen der KI-EsEO-ST

Die Klassifikation durch das Künstliche Neuronale Netz (KNN) erfolgt auf Basis dieser Eingangsdaten (Messwerte) und liefert als Ausgangsgröße den fehlerbehafteten Abgang. Die Ausgabe ist als ganzzahliger Wert (Integer) codiert, wobei jeder numerische Wert eindeutig einem spezifischen Abgang im Stromnetz zugeordnet ist.

3 Simulationen

Kapitel 3 beschreibt die Durchführung der Simulationen in zwei exemplarisch ausgewählten Referenzstromnetzen. Nach der Vorstellung dieser Netze werden die optimierten Hyperparameter definiert, der Trainingsvorgang erläutert und die Ergebnisse präsentiert.

3.1 Referenzstromnetze

Folgende Stromnetze wurden untersucht:

- MS-1: Strahlenförmiges 20-kV-Kabelnetz
- MS-2: 20-kV-Mittelspannungsnetz mit Strahlen- und Ringstruktur

3.1.1 Strahlenförmiges 20-kV-Kabelnetz (MS-1)

Im ersten Schritt wird die KI-basierte Erdschlusssortung mit stationären Größen (KI-EsEO-ST) in einem einfachen, strahlenförmig aufgebauten Mittelspannungsnetz MS-1 konzipiert, entwickelt und validiert. Ziel ist es, das herkömmliche wattmetrische Erdschlusssortungsverfahren durch die neue Methode zu ersetzen. Das untersuchte Kabelnetz umfasst jeweils ein Erdschlusssortungssystem am Anfang der Abgänge A (Abgang 1) und B (Abgang 2) sowie ein Ersatzmodell für das restliche, fehlerfreie Stromnetz. Im Fehlerfall signalisiert das Schutzgerät P2 den Erdschluss im Abgang A in Rückwärtsrichtung, während das Schutzgerät P3 ihn in Vorwärtsrichtung anzeigt.




Bild 3 Netztopologie des Stromnetzes MS-1

3.1.2 20-kV-Mittelspannungsnetz mit Strahlen- und Ringstruktur (MS-2)

Im zweiten Schritt wurde die KI-basierte Erdschlusssortung mit stationären Größen (KI-EsEO-ST) für das nachfolgende Mittelspannungsnetz MS-2 konzipiert, entwickelt und validiert. Die Struktur der Netztopologie ist in Bild 4 dargestellt.

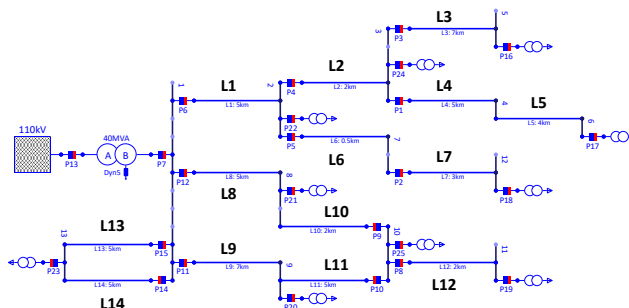


Bild 4 Netztopologie des Stromnetzes MS-2

Es wurde die gleiche Vorgehensweise wie beim Mittelspannungsnetz MS-1 gewählt, um eine Vergleichbarkeit der Ergebnisse sicherzustellen. Ziel ist es einerseits, die Funktionsweise der KI-basierten Erdschlusssortung (KI-EsEO-ST) auch in diesem Stromverteilungsnetz zu überprüfen, und andererseits mögliche Auswirkungen der komplexeren Netztopologie auf deren Arbeitsweise zu identifizieren.

Die im Stromnetz MS-2 enthaltenen Leitungen werden in den Abgängen nach Tabelle 1 zusammengefasst.

Abgang Nr.	Leitungen
1	L1, L2, L3, L4, L5, L6, L7
2	L8, L10
3	L13
4	L9, L11
5	L14
6	L12

Tabelle 1 Definition der Abgänge im Stromnetz MS-2

3.2 KNN-Architekturen

Für die Leistungsfähigkeit eines Künstlichen Neuronales Netzes (KNN) spielen neben der Netzarchitektur auch die sogenannten Hyperparameter eine entscheidende Rolle. Dabei handelt es sich um Einstellgrößen, die das Lernverhalten und die Struktur des Netzes bestimmen – etwa die Anzahl der Schichten und Neuronen, die Lernrate oder die Größe der Trainingsbatches. Diese Parameter werden vor dem Training festgelegt und stochastisch variiert, um eine möglichst hohe Erkennungsgenauigkeit zu erreichen. Die nachfolgende Tabelle 2 gibt einen Überblick über die verwendeten Hyperparameter und deren gewählte Werte.

Hyperparameter	MS-1	MS-2
Anzahl verdeckte Schichten	1	3
Anzahl Neuronen je verdeckte Schicht	9	9
Aktivierungsfunktion	reLU [6]	reLU
Lernalgorithmus	Adam [7]	Adam
Lernrate	0,0001	0,0001
Batch Size	4	4
Fehlerfunktion	MSE [6]	MSE
Anzahl Epochen	100	100

Tabelle 2 Konfiguration der Hyperparameter

Zur Abschätzung der geeigneten Anzahl von Neuronen in den verdeckten Schichten kann eine bewährte Faustformel herangezogen werden. Diese liefert eine erste Orientierung zum Design des KNN und basiert auf Erfahrungswerten aus der Praxis. In durchgeführten Vorversuchen hat sich gezeigt, dass das auf diese Weise gewählte Design des KNN eine gute Ausgangsbasis für das Training darstellt und zu stabilen sowie präzisen Ergebnissen führt. Die verwendete Berechnungsvorschrift ist nachfolgend in Formel 1 dargestellt [5]. Wird die Anzahl der Neuronen in jeder verdeckten Schicht als konstant angenommen, so lässt

sich die Anzahl M der künstlichen Neuronen in den verdeckten Schichten aus der Anzahl der Ein- und Ausgabeneuronen, A und B abschätzen.

$$M = \frac{2}{3} \cdot A + B \quad (1)$$

4 Ergebnisse der Simulationen

In Kapitel 4 werden die Ergebnisse der Simulationen in den zwei verschiedenen Stromnetzen MS-1 und MS-2 präsentiert. Die Unterkapitel behandeln jeweils die Analyse und Bewertung der KI-basierten Erdschlussortung, um netzabhängige Unterschiede und die Genauigkeit der Methode aufzuzeigen.

Zur Darstellung der Ergebnisse und zur Beurteilung der Klassifikationsleistung wird für jedes Stromverteilungsnetz eine Konfusionsmatrix verwendet. Diese ermöglicht eine anschauliche Visualisierung, wie häufig die Erdschlüsse korrekt den jeweiligen Abgängen zugeordnet wurden und an welchen Stellen Fehlklassifikationen aufgetreten sind. Somit liefert die Konfusionsmatrix eine Übersicht über die Genauigkeit und die Fehlerverteilung des KI-Modells.

Es zeigt sich, dass der Trainingsprozess eines Künstlichen Neuronales Netzes (KNN) im Vergleich zur klassischen Entwicklung mathematisch-algorithmischer Software einen entscheidenden und innovativen Vorteil bietet: Bereits während des Trainings entstehen automatisch Performancedaten, die eine direkte Bewertung des Modells nach Abschluss des Trainings ermöglichen. Darüber hinaus lässt sich – analog zur Netzschutztechnik – auch eine KI-gestützte Erdschlusserfassung mit etablierten Prüfverfahren, wie etwa Sekundärprüfeinrichtungen oder virtuellen Testumgebungen, zuverlässig validieren.

4.1 Ergebnisse MS-1

Bild 5 zeigt die Konfusionsmatrix für das Stromverteilungsnetz MS-1. Zur Generierung der Trainingsdaten wurden ca. 6.000 Erdschlussimulationen verwendet, zur Validierung des trainierten KNN ca. 1.200 Erdschlussimulationen.

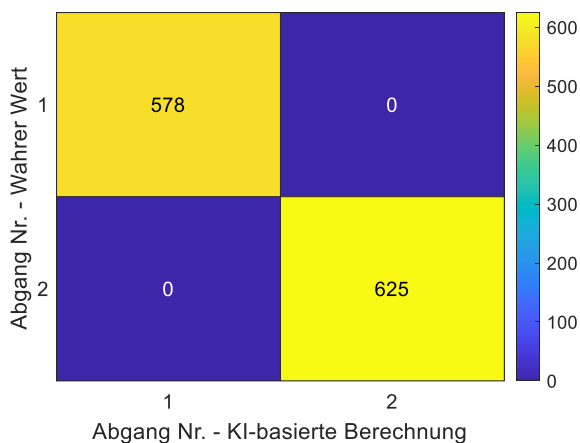


Bild 5 Netztopologie des Stromnetzes MS-1

Dabei wird deutlich, dass alle Erdschlussortungen in den Testdaten korrekt identifiziert werden.

4.2 Ergebnisse MS-2

Bild 6 zeigt die Konfusionsmatrix für das Stromnetz MS-2. Zur Generierung der Trainingsdaten wurden ca. 42.000 Erdschlussimulationen verwendet, zur Validierung des trainierten KNN ca. 8.400 Erdschlussimulationen. Alle Erdschlussortungen, die auf der Hauptdiagonalen abgebildet sind, wurden korrekt erkannt. Vereinzelt treten jedoch auch Fehlzugeordnungen auf – in den meisten Fällen handelte es sich dabei um benachbarte Abgänge.

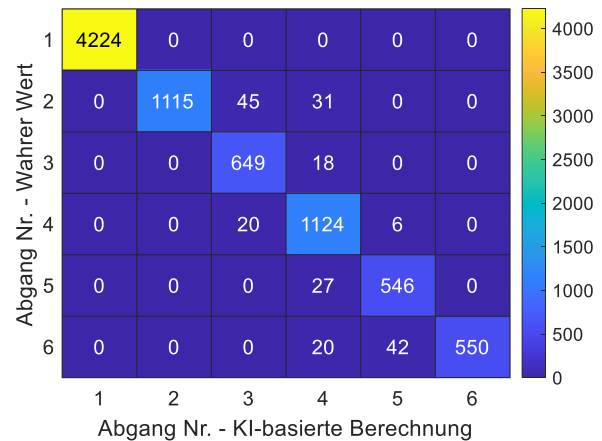


Bild 6 Netztopologie des Stromnetzes MS-2

5 Zusammenfassung und Ausblick

Die entwickelten KNN-Modelle als Kern des KI-Systems zeigen sich nach ersten Laboruntersuchungen als geeignete Klassifikatoren für die Erkennung und Ortung von Erdschlüssen. Die daten- und rechenintensive Trainingsphase erfolgt offline und erfordert den Einsatz von Netzberechnungsprogrammen, die stationäre Netzzustände im Erdschlussfall berechnen können. Die KNN-Modelle liefern im Online-Betrieb die Klassifikationen und Erdschlussortung, d.h. die EsEO-ST, sehr schnell und robust auch gegenüber fehlenden oder verfälschten Eingangssignalen. Zur Berücksichtigung exogener Beeinflussungen (z. B. Temperatur, Luftfeuchtigkeit, usw.) können die KNN-Modelle um zusätzliche Eingangsneuronen erweitert werden. Auch ist es möglich, die Messwerte von Nullspannung und Nullstrom zusätzlich zu den Leitergrößen von Spannungen und Strömen als Eingangsneuronen zu berücksichtigen. Durch eine Wiederholung der Trainingsphase können die online eingesetzten KI-Systeme verbessert und bei Bedarf aktualisiert werden. Als vorteilhaft zeigt sich, dass der Trainingsprozess des KNN automatisch Performancedaten liefert, die eine direkte Bewertung des KI-Systems nach Abschluss des Trainings ermöglichen. Gerade die Trennung zwischen der offline Trainingsphase und dem online Einsatz der KI-EsEO bietet eine hohe Flexibilität für zukünftige Entwicklungen, Anpassungen und Anwendungs-

möglichkeiten. Die zukünftige Forschungs- und Entwicklungsarbeit erstreckt sich von der Implementierung des Verfahrens auf entsprechender Industriehardware hin zu der Validierung in einem Feldtestgebiet.

6 Literatur

- [1] M. Igel, „ATPDesigner“, 19.09.2025. [Online]. Verfügbar: www.atpdesigner.de.
- [2] A. Winter und M. Igel, „Innovative maschinelle Lernverfahren für KI-basierte Lösungen zur Erdschlussrichtungserkennung und -ortung,“ in STE 2022 – Sternpunktbehandlung in Netzen bis 110 kV (D-A-CH), Esslingen, 2022.
- [3] M. Deru und A. Ndiaye, *Deep Learning mit TensorFlow, Keras und TensorFlow.js*, Rheinwerk Verlag, 2020.
- [4] A. Paszke et al., „PyTorch: An Imperative Style, High Performance Deep Learning Library“, gehalten auf der 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), Vancouver, Canada.
- [5] J. Heaton, *Introduction to neural networks with Java*, 2. Ed., 1. Print. St. Louis, Mo: Heaton Research, 2008.
- [6] A. Winter, „Entwicklung einer hybriden Künstlichen Intelligenz für die Identifikation und Optimierung von Netzzuständen in elektrischen Verteilungsnetzen,“ Dissertation, TU Dresden, 2025.
- [7] D. P. Kingma und J. Ba, „Adam: A Method for Stochastic Optimization.“ [Online]. Verfügbar: <http://arxiv.org/pdf/1412.6980v9> (Zugriff am 31.07.2020).
- [8] VDE ETG, *Leitfaden zur Sternpunktbehandlung in Netzen bis 110 kV (D-A-CH)*, Berlin: VDE Verlag GmbH, 2022.