

Forschungsberichtsblatt

IT-basierte Netzausbauplanung im Verteilnetz für ein erneuerbares dezentrales Energiesystem (IT-Grid-Design)

von

Manuela Linke, Tobias Meßmer, Gabriel Micard, Adrian Wenzel, Gunnar Schubert

HTWG Konstanz
Fakultät Elektro- und Informationstechnik

Adrian Minde, Kristian Peter

ISC Konstanz
Abteilung Systeme und Anwendungen

Wolfgang Biener, Christof Wittwer

Fraunhofer ISE
Abteilung Intelligente Netze

Förderkennzeichen: BWSGF18001

Die Arbeiten des Baden-Württemberg-Programms Lebensgrundlage Umwelt und ihre
Sicherung (BWPLUS) werden mit Mitteln des Landes Baden-Württemberg gefördert

September 2020

1. Kurzbeschreibung der Forschungsergebnisse

Durch die zunehmende Integration von regenerativen Energieerzeugungsanlagen und Elektroladesäulen in die Verteilnetze ergeben sich schwer prognostizierbare Einspeise- und Verbrauchsvorgänge, die zu Überlastungen der Betriebsmittel führen können. Konventionelle Netzberechnungstools benötigen viel Rechenzeit und eignen sich daher nicht, um auf kurzfristig auftretende Störfälle im Netz zu reagieren. Aus diesem Grund basiert das im Rahmen von IT-Grid-Design entwickelte Netzoptimierungstool auf einem künstlichen neuronalen Netz (KNN). Der entscheidende Vorteil dabei ist, dass ein trainiertes KNN in weniger als einer Sekunde eine Lösung bereitstellen kann. Der Optimierer ist damit in der Lage, auf kurzfristige Störungen, verursacht durch beispielsweise hohe Einspeisungen aus PV-Systemen oder das Laden von Elektrofahrzeugen, zu reagieren. Dazu kann der Verteilernetzbetreiber Kapazitäten und Flexibilität, die das vorhandene Netz bietet, bestmöglich nutzen und eine aktive Steuerung vornehmen, um das Netz zu stabilisieren. Die Notwendigkeit eines kostenintensiven Netzausbaus im Mittel- und Niederspannungsnetz kann dadurch verringert oder sogar verhindert werden.

Generierung des Trainingsdatensatzes

Zum Training des KNN wurden zunächst Störfälle generiert, die auf realen Erzeugungs- und Lastprofilen aus dem CoSSMic-Projekt basieren¹. Der Trainingsprozess des KNN wird mittels überwachtem Lernen durchgeführt. Die dafür benötigten Daten enthalten ein möglichst umfassendes Abbild aller möglichen Störfälle, die in dem betrachteten Stromnetz auftreten können. Für jeden Störfall wurde aus allen möglichen und sinnvollen Netzkonfigurationen eine optimierte Netztopologie zur Lösung des vorliegenden Problems anhand von Lastflussberechnungen ermittelt. Durch die Variation der Stufenschalter der Transformatoren und der Stellungen aller installierten Schalter im Netz wurde berechnet, wie der Stromfluss gelenkt werden muss, damit keines der Betriebsmittel die zulässigen Belastungsgrenzen mehr überschreitet. Um die beste der möglichen Lösungen für den vorliegenden Störfall auszuwählen, wurde jeweils eine der folgenden drei Netzbetriebsstrategien verfolgt:

- 1) Minimierung der Verlustleistung in den Leitungen
- 2) Minimierung der Summe der Abweichungen von der Nennspannung an den Netzanschlusspunkten
- 3) Minimierung der Anzahl an Steuerungshandlungen zur Behebung des vorliegenden Störfalls

¹ Open Power System Data. 2017. Data Package Household Data. Version 2017-11-10.

https://doi.org/10.25832/household_data/2017-11-10. (Primary data from various sources, for a complete list see URL).

Dadurch werden Paare aus Störfall und Lösung generiert, mit denen das KNN trainiert werden kann. In Abbildung 1 ist dieser Vorgang in einem Ablaufdiagramm dargestellt.

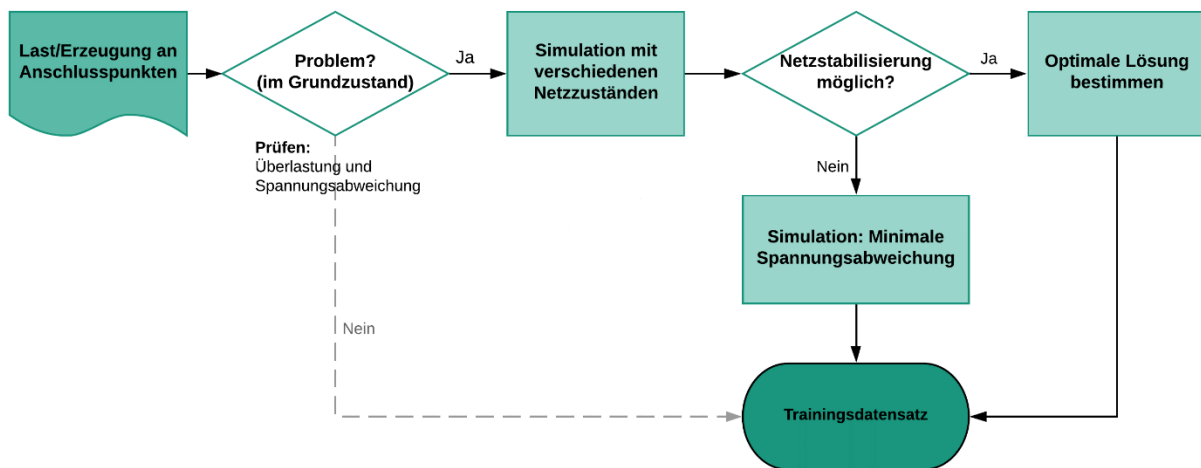


Abbildung 1: Flussdiagramm zur Erzeugung des Trainingsdatensatzes.

Für das Training von neuronalen Netzen sind sowohl die Qualität als auch die Quantität der Trainingsdaten wichtig, damit das KNN auf jeglichen möglichen Störfall im Netz reagieren kann. Daher wurde ein Betriebsführungsalgorithmus entwickelt, mit dem Trainingsdaten für den KI-Algorithmus generiert werden können, die den netzdienlichen Einsatz der Flexibilitäten der neuen Netzteilnehmer wie PV-Anlagen oder Elektrofahrzeuge ermöglichen.

Training des KNN

Die Abbildung 2 zeigt eine Darstellung eines künstlichen neuronalen Netzes. Der Input, sprich die Störung im Stromnetz, muss für das Training des KNN in einen Vektor überführt werden. Die Elemente des Vektors beschreiben den Zustand des Netzes anhand der Netzkonfiguration und der vorliegenden gemessenen Leistungen. Das KNN generiert einen Outputvektor mit Wahrscheinlichkeiten. Die Elemente des Outputvektors stehen jeweils für eine mögliche Netzkonfiguration. Das Element mit der höchsten Wahrscheinlichkeit ist die vorgeschlagene Lösung, die in lesbare Form konvertiert werden muss. Diese beschreibt, welche Schalthandlungen durch den Netzbetreiber ausgeführt werden müssen, um den vorliegenden Störfall zu lösen. Zu Beginn des Trainings prognostiziert das KNN eine Lösung, die eine Zufallslösung ist. Durch den Vergleich der vorhergesagten mit der berechneten Lösung werden die Gewichte des KNN aktualisiert. Dieser Vorgang wird wiederholt, bis die Vorhersagerate maximal wird.




Abbildung 2: Darstellung eines neuronalen Netzes. Weitere Erklärung siehe Text.

Um die Vorhersagewahrscheinlichkeit des neuronalen Netzes zu erhöhen, wurden sowohl verschiedene Hyperparameter des Trainings als auch die Anzahl an möglichen Lösungsklassen variiert, um deren Einfluss auf den Trainingserfolg zu bewerten.

Implementierung

Das virtuelle Testnetz

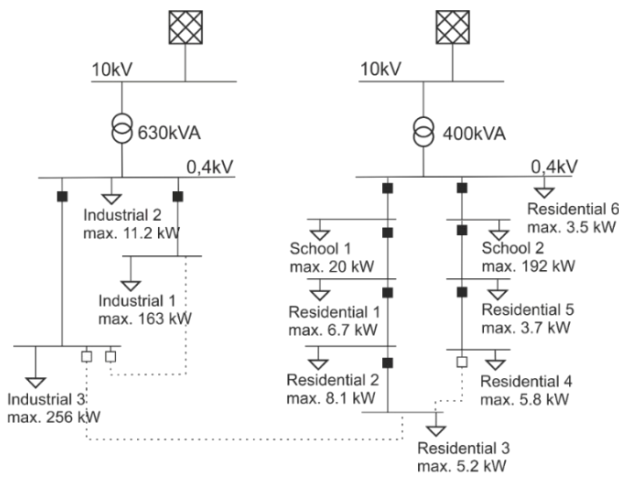


Abbildung 3: Das virtuelle Testnetz in Standard-Netzkonfiguration. An den Anschlusspunkten ist der jeweilige maximale Leistungswert angegeben aus dem CoSSMic-Projekt. Die Quadrate an den Leitungen stellen die fernsteuerbaren Schalter. Gefüllte Quadrate stehen für geschlossene, leere für offene Schalter.

In Zusammenarbeit mit unserem Projektpartner der Firma Siemens wurde ein virtuelles Testnetz entworfen, welches in Abbildung 3 dargestellt ist. Das Testnetz besteht aus zwei Bereichen: Einem Industrieareal und einem Wohnareal, die jeweils über einem Transformator mit der darüber liegende Netzebene verbunden sind. In dem Netz sind drei Industriebetriebe, sechs Wohngebäude und zwei Transformatoren angesiedelt. Zusätzlich zu den Stufenschaltern der beiden Transformatoren kann das Netz über elf fernsteuerbare Schalter gesteuert werden. Die dargestellte Standard-Netzkonfiguration wurde nach gängiger Praxis der Netzbetreiber definiert.

Die Daten aus dem CoSSMic-Projekt enthalten erhobene Lastzeitreihen von Industrien, Schulen und Privathaushalten.

Ergebnisse

Die hier vorgestellten Ergebnisse wurden bereits größtenteils veröffentlicht [1], [2]. Als Grundlage für die Trainingsdaten wurden Daten aus dem CoSSMic-Projekt verwendet, die durch den Forschungspartner ISC Konstanz zur Verfügung gestellt wurden. Es wurden stets die maximale Leistung der Verbraucher eingestellt und zusätzlich drei der Verbraucher auf einen Wert der zwei- oder dreimal höher ist als die Maximalleistung. Auf diese Weise wurden 8160 Störfälle generiert. Für jeden dieser Störfälle wurde mit den bereits beschriebenen Simulationsverfahren die optimale Netzkonfiguration zur Behebung der Störung als Lösung des Störfalles berechnet. Mit den Paaren aus Störfällen und Lösungen konnte anschließend das Training zur Modellierung des KNNs durchgeführt werden. Das KNN wurde für drei unterschiedliche Netzmanagementstrategien trainiert. Dazu wurden den Störfällen verschiedene Lösungen zugeordnet und zu jeder Strategie ein unabhängiges KNN berechnet. Je nach Netzbetriebsstrategie wurde eine Vorhersagewahrscheinlichkeit zwischen 88 und 91 Prozent erreicht. Die Werte sind in Tabelle 1 aufgeführt.

Tabelle 1: Vergleich der Trainingsergebnisse der einzelnen Netzbetriebsstrategien

Vorhersagewahrscheinlichkeit der verschiedenen Netzbetriebsstrategien in Prozent	
Minimierung der Verlustleistung in den Leitungen	88,3
Minimierung der Abweichungen von der Nennspannung	88,2
Minimierung der Anzahl an Steuerungshandlungen	91,4

N-Best Methode

Bei der Suche nach der besten Lösung nach den drei oben beschriebenen Kriterien konnte kein zufriedenstellendes Ergebnis erreicht werden. Der Netzbetreiber benötigt eine deutlich höhere Sicherheit, um sich auf den Algorithmus verlassen zu können. Deshalb wurde eine weitere Methode angewandt, um die Wahrscheinlichkeit die richtige Lösung zu finden zu erhöhen. In der N-Best Methode wird die beste Lösung unter den N Elementen des Outputvektors mit den höchsten Wahrscheinlichkeiten gesucht. Um die beste Lösung zu ermitteln wird im Anschluss jeweils eine Lastflussberechnung der N Lösungen durchgeführt und somit die beste Lösung aus den N besten Lösungen bestimmt.

Zur Bestätigung der Funktion dieser Methode wurde das KNN, das mit der Managementstrategie zur Minimierung der Verlustleistung in den Leitungen modelliert wurde, herangezogen. In den vier Lösungen mit der höchsten Wahrscheinlichkeit konnte die beste Lösung zu 98,8 Prozent gefunden werden. Die benötigte Rechenzeit verlängerte sich dadurch auf unserem Simulationsrechner um etwa 0,1 Sekunden. Die Ergebnisse sind in Abbildung 4 dargestellt.

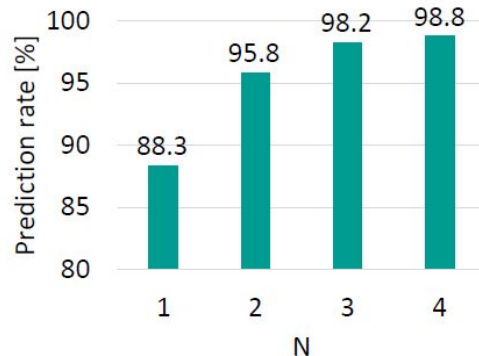


Abbildung 4: Ergebnisse der N-Best Methode

CNNs

Weiterhin wurde untersucht, ob der Einsatz von Convolutional Neural Networks (CNNs) als Basis für den Optimierungsalgorithmus vorteilhaft ist. Die Vorhersagewahrscheinlichkeit beim Verwenden eines CNNs konnte im Vergleich zum KNN von 88,3% auf 93,5% gesteigert werden.

Vergleich zur konventionellen Netzausbauoptimierung

Zusätzlich wurde der Vergleich zu einer klassischen Netzausbauoptimierung durchgeführt. Bei einer Elektromobilitäts-Durchdringung von 10 % konnten von den 431 erkannten Störfällen 184 durch die Anwendung des Schaltalgorithmus gelöst werden. Damit konnte in ca. 43% der Fälle ein Netzausbau mit durchschnittlichen Kosten von 1212 Euro (reine Anschaffungskosten) vermieden werden.

Weitere Untersuchungen ergaben, dass eine Kombination von Netzausbau der am Häufigsten von Störfällen betroffenen Betriebsmittel und dem HTWG Netzführungsalgorithmus die Anzahl an kritischen Störfällen verringern kann. Zu diesem Zweck wurden drei unterschiedliche Netzausbauszenarien verglichen. Aufgrund der Sterntopologie des betrachteten Netzes ist jedoch die Integration neuer Netzteilnehmer an den Ausläufen der Strahlen nur bedingt ohne Netzausbau möglich.

Analyse der praktischen Anwendbarkeit

Anschließend wurde die praktische Anwendbarkeit der entwickelten Algorithmen auf reale Stromnetze unter Verwendung realer Messzeitreihen untersucht. Dazu wurden von unserem assoziierten Projektpartner Stadtwerk am See die Netzdaten eines Quartiers in Friedrichshafen bereitgestellt. Für das Training wurden mit Hilfe einer Halton-Sequenz kontinuierliche Lastzustände generiert. Die KNNs wurden mit gemessenen Lastzeitreihen, in die zusätzliche 200 kW Elektromobilität an unterschiedlichen Stellen im Netz integriert wurden, getestet. Das KNN, welches auf die Erkennung von lösbaren Störfällen trainiert wurde, konnte eine Vorhersagewahrscheinlichkeit von 80% erreichen.

Anschließend wurde der Ausfall einer Leitung im Netz simuliert. Der Algorithmus sollte so schalten, dass weiterhin alle Netzteilnehmer versorgt sind und dabei die zulässigen Netzspezifikationen eingehalten werden. Insgesamt wurde in 93 % der Testdaten von dem trainierten Algorithmus richtig erkannt.

2. Welche Fortschritte ergeben sich für die Wissenschaft und/oder Technik durch die Forschungsergebnisse?

Für ein zukunftsfähiges Stromnetz müssen Stromerzeuger, Netzbetreiber, Speicher und Kunden mittels modernen Informations- und Kommunikationstechnologien intelligent vernetzt und verknüpft werden. Die zusätzlichen Informationen, die dadurch für die Netzbetreiber der Verteilnetze verfügbar werden, können für eine intelligente Netzbetriebsführung nützlich sein, um mit verringerten Netzausbaukosten trotzdem eine hohe Integration von fluktuierenden Energieerzeugern wie PV Anlagen und neuen elektrischen Verbräuchen wie Wärmepumpen oder Elektroladesäulen zu ermöglichen. Der im Rahmen dieses Forschungsprojektes entwickelte und untersuchte KI-Regler kann eine zentrale Schlüsselfunktion darin spielen die Energiewende durch die Nutzung neuer, innovativer Technologien zum Erfolg zu bringen. Im Vergleich des KI-Netzführungsalgorithmus zu einer klassischen Netzausbauroptimierung konnte gezeigt werden, dass Einsparungen durch die Anwendung des Algorithmus möglich sind.

3. Nutzen, insbesondere praktische Verwertbarkeit der Ergebnisse und Erfahrungen

Die Systemanforderungen für den Betrieb von Stromnetze sind hoch, um jederzeit die Sicherheit der Energieversorgung zu gewährleisten. Aus diesem Grund wird der entwickelte Netzoptimierer im Rahmen des Forschungsvorhabens *KI – basierte Planung und Betriebsführung von Verteilnetzen und Microgrids zur optimalen Integration regenerativer Erzeuger und fluktuierender Lasten im Rahmen der Energiewende (AI4Grids)* vom Bundesumweltministerium im Rahmen der Initiative „KI-Leuchttürme für Umwelt, Klima, Natur und Ressourcen“ weiterentwickelt (FKZ: 67KI2012A). Um die Stabilität der Mittel- und Niederspannungsnetzen in Zukunft zu gewährleisten ohne große finanzielle Mittel für einen Ausbau der Netze aufbringen zu müssen, kommt der Synchronisierung von erneuerbaren Energien und den verfügbaren Netzkapazitäten eine Schlüsselrolle zu. Daher werden in Zukunft die Flexibilitäten der neuen Netzteilnehmer in den Algorithmus integriert. Ein weiteres zukünftiges Anwendungsgebiet des Optimierers wird die Unterstützung von Verteilnetzbetreibern bei der Investitionsplanung sein, indem mit Hilfe des entwickelten Algorithmus die optimale Position für neue Netzverstärkungsmaßnahmen hinsichtlich der Energieeffizienz ermittelt wird.

4. Ergebnis- und Forschungstransfer

Die innerhalb des Projektzeitraumes gewonnenen Erkenntnisse wurden in der Projektlaufzeit auf verschiedenen Konferenzen präsentiert. Dabei entstanden die folgenden Veröffentlichungen:

[1] M. Linke, T. Messmer, G. Micard, A. Wenzel, G. Schubert, M. Kindl und A. Minde, „Artificial neural network based decision support system for the present power grid accounting for the successful integration of renewable energy sources such as pv systems,“ To be published in the proceedings of the 36th European PV Solar Energy Conference and Exhibition, 2019.

[2] A. Wenzel, M. Linke, T. Meßmer, G. Micard, G. Schubert, A. Minde und M. Kindl, „Innovative grid optimization approach based on artificial neural networks,“ To be published in the proceedings of the 2019 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe).

[3] M. Linke, T. Messmer, G. Micard, A. Wenzel, G. Schubert, M. Kindl und A. Minde.
„Netzoptimierungstool auf Basis künstlicher neuronaler Netze für den intelligenten
Echtzeitbetrieb des Stromnetzes auf Verteilnetzebene“. Tagungsband des 26. REGWA
Symposium (Nutzung Regenerativer Energiequellen und Wasserstofftechnik 2019, ISBN 978-3-
9817740-4-7). 2019.

Teilergebnisse des Projekts sind an der HTWG Konstanz in die Lehrveranstaltungen „Einführung in
das maschinelle Lernen“ und „Energiespeichersysteme“ eingeflossen. Des Weiteren wurde innerhalb
des Projekts ein Masterprojekt angefertigt:

Michael Keszler, „Analyse und Vergleich der Netzsimulationstools OpenDSS und pandapower
hinsichtlich ihrer Eignung zur Generierung von Trainingsvektoren für ein künstliches neuronales
Netzwerk“, Masterprojekt, HTWG Konstanz, 04.11.2018

Im Projekt *„KI – basierte Planung und Betriebsführung von Verteilnetzen und Microgrids zur
optimalen Integration regenerativer Erzeuger und fluktuierender Lasten im Rahmen der
Energiewende (AI4Grids)“*, ab 01.09.2020 gefördert vom Bundesministerium für Umwelt, Naturschutz
und nukleare Sicherheit (FKZ: 67KI2012A), wird der in diesem Projekt entwickelte Regler
weiterentwickelt und mit weiteren Aspekten zur Betriebsführung wie beispielsweise Prognosen,
Netzzustandsschätzungen kombiniert. Diese Algorithmen werden nach einer Testphase im Labor in
realen Netzgebieten eingesetzt und für den Einsatz in der Praxis optimiert. Ziel ist, durch den Einsatz
der auf KI basierenden Regler Netzausbaukosten zu minimieren.