

AI4Grids

Schlussbericht

Teil I – Kurzbericht

Förderkennzeichen: 67KI2012B

Autor: Bodo Rückauer

Zuwendungsempfänger:

Fraunhofer-Institut für Solare Energiesysteme ISE

Förderkennzeichen:

67KI2012B

Vorhabenbezeichnung:

AI4Grids: KI-basierte Planung und Betriebsführung von Verteilnetzen und Microgrids zur optimalen Integration regenerativer Erzeuger und fluktuierender Lasten im Rahmen der Energiewende

Laufzeit des Vorhabens:

01.09.2020 – 31.12.2023

Berichtszeitraum:

01.09.2020 – 31.12.2023

Projektleiter/-in:

Dr.-Ing. Bernhard Wille-Haussmann, Fraunhofer-Institut für Solare Energiesysteme ISE

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren.

Danksagung

Das Forschungsprojekt AI4Grids wurde in der Zeit vom 01.09.20 bis zum 31.12.23 durch den Projektträger Zukunft – Umwelt – Gesellschaft (ZUG) unter dem Förderkennzeichen 67KI2012B betreut. Die Finanzierung erfolgte aufgrund eines Beschlusses des Deutschen Bundestages durch das Bundesministerium für Umwelt, Naturschutz und Nukleare Sicherheit, wofür wir uns herzlich bedanken.



**Bundesministerium
für Umwelt, Naturschutz
und nukleare Sicherheit**

Das Vorhaben wurde als Verbundprojekt vom Fraunhofer-Institut für Solare Energiesysteme ISE, der HTWG Konstanz, dem ISC Konstanz, den Stadtwerken Konstanz, dem Stadtwerk am See und der Energiedienst Holding AG gemeinsam durchgeführt. Dieser Bericht beinhaltet eine Beschreibung der Arbeiten und Ergebnisse des Verbundpartners Fraunhofer ISE. Für die Arbeiten in den angeschlossenen Teilprojekten wird ein separater Abschlussbericht von Seiten der Verbundpartner eingereicht.

Inhalt

1. Aufgabenstellung.....	4
2. Wissenschaftlicher und technischer Stand	4
3. Ablauf des Vorhabens	4
4. Projektergebnisse.....	5
5. Zusammenarbeit mit anderen Stellen.....	5

1. Aufgabenstellung

Um den Klimawandel zu verlangsamen, braucht es eine Abkehr von fossilen Energiequellen. Der notwendige Ausbau der erneuerbaren Energien und die Elektrifizierung der Wärme- und Verkehrssektoren stellt das Stromnetz jedoch vor Herausforderungen: Solar- und Windenergie speisen Strom sehr unregelmäßig in das Stromnetz ein, während der Strombedarf vor allem in den Städten stark steigt. Flexible Verbraucher wie Elektroautos und Wärmepumpen können im Zusammenspiel mit den schwankenden regenerativen Erzeugern aber zur Lösung für die Energiewende beitragen - durch eine intelligente Netzsteuerung.

Ziel des Projekts war es, Algorithmen intelligenter Netzbetriebsführung zu entwickeln, mit denen fluktuierende Erzeuger und Verbraucher effizient in das Mittel- und Niederspannungsnetz integriert werden können. Durch die gezielte Regelung von Verbrauchern und eine verlässliche Prognose der Erzeugung soll das Netz vor kritischen Belastungen geschützt und eine stabile Stromversorgung sichergestellt werden können.

2. Wissenschaftlicher und technischer Stand

Der Einsatz von künstlichen neuronalen Netzen wurde zu Beginn des Projekts von der Forschung hauptsächlich zum Betrieb von Übertragungsnetzen untersucht, bspw. um automatisch Messungen auszuwerten und im Störfall Fehlerort und Fehlertyp zu identifizieren^{1,2,3}. Im Zusammenhang mit Verteilnetzen wird KI bisher zur Vorhersage von zukünftiger Stromerzeugung anhand von Wetterdaten genutzt⁴. Ziel ist häufig, Kostenanreize für die Nutzung von elektrischem Strom zu Zeiten mit hoher Erzeugung und geringem Verbrauch zu setzen.

Mit der zunehmenden Verfügbarkeit von Daten aus intelligenten Messsystemen gewinnt deren Nutzbarkeit für intelligenten Netzbetrieb an Bedeutung. Eine Anwendung ist die Last-Disaggregation, mit der große Verbraucher wie z.B. Elektrofahrzeuge identifiziert werden können⁵. Im Projekt AI4Grids wurde dieser Ansatz auf neu angeschlossene Ladestationen und Wärmepumpen erweitert. Messdaten können auch verwendet werden, um synthetische Netzmodelle zu validieren bzw. zu korrigieren⁶. Diese Ansätze wurden in AI4Grids durch KI-basierte Mustererkennungsverfahren weiterentwickelt.

Zustandsschätzung ist in den Übertragungsnetzen ein standardmäßig genutztes Verfahren und nun zunehmend auch in der Verteilnetzebene erforderlich – ein wesentlicher Treiber ist hier die Novellierung des EnWG §14a. Die schlechte Beobachtbarkeit und Asymmetrie im Verteilnetz stellen konventionelle Methoden allerdings vor Herausforderungen. AI4Grids baut auf früheren Arbeiten auf, welche eine Verbesserung der Netzzustandsschätzung mit Daten aus intelligenten Messsystemen postulieren.⁷

3. Ablauf des Vorhabens

Der zeitliche Ablauf des Vorhabens zusammen mit einer Auflistung der Arbeitspakete ist der folgenden Tabelle zu entnehmen. Das Projekt wurde aufgrund von Einstellungsverzögerungen während der Corona-Pandemie kostenneutral um sechs Monate verlängert.

¹ <https://www.siemens.com/global/en/products/energy/topics/dyna-grid-center.html>

² B. Donnot „Fast Power system security analysis with Guided Dropout“. In Proc. 26th European Symposium on Artificial Neural Networks. 2018

³ B. Donnot „Anticipating contingencies in power grids using fast neural net screening“. In Proc. IEEE Int. Joint Conf. Neural Networks. 2018

⁴ D. Riley, G.K. Venayagamoorthy, "Characterization and modeling of a grid connected photovoltaic system using a recurrent neural network". In Proc. IEEE Int. Joint Conf. Neural Networks. 2011

⁵ Christie, I. N., Fesche, B. I. & Ingebrigtsen, K. Automated Detection of Electric Vehicles in Hourly Smart Meter. 3–6 (2019). CIRED.

⁶ Taxt, H., Kirkeby, H. & Seljeseth, H. "New methods for distribution network monitoring with smart meters – verifying data in network information systems". In 23rd International Conference on Electricity Distribution (CIRED) (2015)

⁷ Al-Wakeel, A., Wu, J. & Jenkins, N. State estimation of medium voltage distribution networks using smart meter measurements. Appl. Energy 184, 207–218 (2016)

Arbeitspaket / Projektmonat	1	2	3	4	5	6	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	
AP1: Projektkoordination																																				
AP2: Entwicklung Algorithmen																																				
AP2.1 Intelligente Betriebs- und Messmittel Planung																																				
AP2.2 Weiterentwicklung des KNN - Reglers																																				
AP2.3 Topologieerkennung der Netzstruktur																																				
AP2.4 Lokalisieren von neuen Netzteilnehmern																																				
AP2.5 Netzzustandsschätzung																																				
AP2.6 Prognose																																				
AP2.7 Entwicklung KI - Gesamtalgorithmus																																				
AP3: Entwicklung und Test Gesamtsystem																																				
AP3.1 Test der einzelnen Algorithmen																																				
AP3.2 Test des Gesamt KI-Algorithmus																																				
AP4: Test und Demonstration in realer Umgebung																																				
AP5: Analyse der technischen und wirtschaftlichen Potentiale																																				

4. Projektergebnisse

Im Fokus des Vorhabens stand die Entwicklung eines KI-basierten Gesamtalgorithmus für eine sichere und effiziente Netzbetriebsführung. Der Gesamtalgorithmus bestand zum Ende des Projekts aus den folgenden Teilen:

- Ein Graph-neuronales Netzwerk zur Netzzustandsschätzung, welches vorhandene Messungen bereinigt und fehlende Messwerte ergänzt. Dieser Prozess ist unverzichtbar in einem unvollständig beobachteten dynamischen System wie dem modernen Verteilnetz und bildet die Grundlage für die unten folgenden Betriebsführungswerkzeuge.
- Ein Graph-neuronales Netzwerk zur Erkennung und Korrektur von Fehlern in Netztopologien. Dieses Werkzeug wird zukünftig die teil-automatisierte Digitalisierung von Verteilnetzdaten ermöglichen.
- Ein Neuronales Netzwerk zur Erkennung von neuen Netzteilnehmern wie Ladestationen und Wärmepumpen.
- Ein Rekurrentes Neuronales Netzwerk, welches an lokale Gegebenheiten angepasste PV-Ertragsprognosen aufgrund von Wetterdaten erstellt.
- Ein probabilistischer Algorithmus, welcher Lastprognosen aufgrund von gebäudespezifischen Metadaten erstellt.
- Ein Neuronales Netzwerk zum Engpassmanagement in der Leitwarte. Dieses nutzt den geschätzten Netzzustand bzw. die Ertrags- und Lastprognosen, um einen möglichen Spannungsabfall oder eine Leitungsüberlastung zu antizipieren und Maßnahmen zur Netzentlastung zu bestimmen. Dazu gehört z.B. die Steuerung eines Schalters, Einstellung einer geeigneteren Trafo-Stufe, oder die Abregelung von Erzeugung oder Verbrauch.

Diese Algorithmen wurden sowohl auf synthetischen Netzen als auch in einer realitätsnahen Simulationsumgebung mit Hardware-in-the-Loop-Infrastruktur (dem Digital Grid Lab am Fraunhofer ISE) erfolgreich getestet. Eine Anwendung des Gesamtalgorithmus im Reallabor ist Gegenstand künftiger Arbeit.

5. Zusammenarbeit mit anderen Stellen

Ein wesentliches Merkmal dieses Vorhabens war es, KI-basierte Algorithmen nicht nur in einer Laborumgebung zu entwickeln, sondern diese auch in realen Umgebungen auf Praxistauglichkeit zu prüfen. Darum wurde das Konsortium aus drei Forschungsinstitutionen (HTWG Konstanz, Fraunhofer ISE, ISC Konstanz) durch drei Praxispartner ergänzt (Stadtwerke Konstanz, Stadtwerk am See, Energiedienst). Der Schwerpunkt der Forschungsinstitutionen lag auf der Entwicklung der KI-Algorithmen sowie den Tests in einer Laborumgebung. Zudem waren sie wesentlich für Generierung, Übertragung und Auswertung der Daten in den Reallaboren verantwortlich. Die Netzbetreiber stellten mit ihren Verbundnetzen und Quartieren Reallabore zu Verfügung und unterstützten das Projekt mit elektrotechnischen Arbeiten, zusätzlichen Daten sowie durch ihre Erfahrung in der Anwendung. Diese enge Zusammenarbeit mit den Praxispartnern sichert den breiten Einsatzbereich der erreichten Ergebnisse hin zum Gelingen der Energiewende.

AI4Grids
Schlussbericht
Teil II – Eingehende Darstellung
Förderkennzeichen: 67KI2012B

Danksagung

Das Forschungsprojekt AI4Grids wurde in der Zeit vom 01.09.2020 bis zum 31.12.2023 durch den Projektträger Zukunft – Umwelt – Gesellschaft (ZUG) unter dem Förderkennzeichen 67KI2012B betreut. Die Finanzierung erfolgte aufgrund eines Beschlusses des Deutschen Bundestages durch das Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit, wofür wir uns herzlich bedanken.

Das Vorhaben wurde als Verbundprojekt vom Fraunhofer-Institut für Solare Energiesysteme ISE, Freiburg, und der HTWG Konstanz, dem ISC Konstanz, dem Stadtwerk am See und dem Energiedienst Holding AG gemeinsam durchgeführt. Dieser Bericht beinhaltet eine Beschreibung der Arbeiten und Ergebnisse des Verbundpartners Fraunhofer ISE im Teilprojekt 67KI2012B. Für die Arbeiten in den angeschlossenen Teilprojekten wird ein separater Abschlussbericht von Seiten der Verbundpartner eingereicht.



Bundesministerium
für Umwelt, Naturschutz
und nukleare Sicherheit

AI4Grids

KI-basierte Planung und Betriebsführung von Verteilnetzen und Microgrids zur optimalen Integration regenerativer Erzeuger und fluktuierender Lasten im Rahmen der Energiewende

Autoren: Bodo Rückauer, Frederik Mayer, Benedikt Köpfer, Carl Wanninger, Jasmin Montalbano,
Bernhard Wille-Haussmann

Fraunhofer-Institut für Solare Energiesysteme ISE
in Freiburg

Förderkennzeichen: 67KI2012B
Berichtszeitraum: 01.09.2020 – 31.12.2023
Projektleitung: Dr.-Ing. Bernhard Wille-Haussmann
bernhard.wille-haussmann@ise.fraunhofer.de, +49 761 4588-5443

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren.

Inhalt

1. Verwendung der Zuwendung und Ergebnisse	5
1.1 AP 1: Koordination und Organisation.....	5
1.2 AP 2: Entwicklung der Algorithmen.....	5
1.2.1 Topologie-Erkennung der Netzstruktur.....	6
1.2.1.1 Topologie-Erkennung	7
1.2.2 Lokalisieren von neuen Netzteilnehmern	13
1.3 AP 3: Test der Algorithmen in Laborumgebung	18
1.3.1 Test der einzelnen Algorithmen im Digital Grid Lab ISE	18
1.3.2 Test des Gesamt KI-Algorithmus im Digital Grid Lab ISE	19
1.4 AP 4 Test und Demonstration in realer Umgebung	26
1.5 AP 5: Analyse technische und wirtschaftliche Potentiale	26
2. Zahlenmäßiger Nachweis	26
3. Notwendigkeit der Arbeit.....	26
4. Verwertbarkeit der Ergebnisse.....	26
5. Relevante Ergebnisse von dritter Seite	27
6. Erfolgte oder geplante Veröffentlichungen	27

1. Verwendung der Zuwendung und Ergebnisse

In den folgenden Unterkapiteln wird die Verwendung der Zuwendung eingehend dargestellt, mit Gegenüberstellung der in der Gesamt- und Teilvorhabenbeschreibung definierten Ziele. Dabei liegt der Fokus auf den Ergebnissen, an denen das Fraunhofer ISE maßgeblich beteiligt war. Details zu den Arbeiten der Verbundpartner sind deren jeweiligem Abschlussbericht zu entnehmen.

1.1 AP 1: Koordination und Organisation

Ziel dieses Arbeitspakets war die Koordination des Gesamtprojektes sowie der einzelnen Arbeitspakete. Hier war die HTWG Konstanz federführend. Das Fraunhofer ISE beteiligte sich an den quartalsweise stattfindenden Gesamtprojekttreffen und den zweiwöchentlichen Treffen der Algorithmenentwickler, wo Schnittstellen der Einzelalgorithmen für den Gesamtalgorithmus definiert und weiterentwickelt wurden. Um die Erkenntnisse aus dem Projekt einer breiten Öffentlichkeit zugänglich zu machen, wurden zwei Symposien an der HTWG Konstanz durchgeführt¹. Zu diesen Symposien wurden Interessierte aus dem gesamten Bundesgebiet eingeladen, um die neuesten Entwicklungen im Einsatz von KI in Verteilnetzen der Nieder- und Mittelspannungsebene zu präsentieren und zu diskutieren. Die Teilnehmerzahlen wurden im separaten Programmmonitoring berichtet. Das Fraunhofer ISE beteiligte sich mit folgenden Vorträgen:

- Netzzustandsschätzung in Verteilnetzen mittels Graph Neural Networks (Jasmin Montalbano)
- Entscheidungsunterstützung in der Netzplanung (Wolfgang Biener & Jasmin Montalbano)
- Wie testet man Regler für Reallabore? (Bernhard Wille-Haussmann)
- Neue Werkzeuge für die Netzplanung (Wolfgang Biener)



Abbildung 1: Übersicht der einzelnen Module des Gesamtalgorithmus im Vorhaben AI4Grids.

1.2 AP 2: Entwicklung der Algorithmen

Der im Rahmen der Energiewende notwendige Ausbau der erneuerbaren Energien und die Elektrifizierung der Wärme- und Verkehrssektoren stellt das Stromnetz vor Herausforderungen. Ziel dieses Arbeitspakets war es, Algorithmen intelligenter Netzbetriebsführung zu entwickeln, mit denen fluktuierende Erzeuger und Verbraucher effizient in das Mittel- und Niederspannungsnetz integriert werden können. Durch die gezielte Regelung von Verbrauchern und eine verlässliche Prognose der Erzeugung sollte das Netz vor kritischen Belastungen geschützt und eine stabile Stromversorgung sichergestellt werden können.

Die Teil-Algorithmen (siehe auch Abbildung 1) umfassen:

1. Topologie-Erkennung der Netzstruktur (Fraunhofer ISE). Dies beinhaltet die Planung von Anzahl und Standorten von Betriebsmitteln und Messgeräten, um ausreichend Daten für Zustandsschätzung und Regelung zu erhalten. (HTWG Konstanz)
2. Lokalisieren von neuen Netzteilnehmern mittels Maschinellen Lernen (Fraunhofer ISE)
3. Netzzustandsschätzung (Fraunhofer ISE)
4. PV-Ertragsprognose aufgrund von Wetterdaten (ISC Konstanz)

¹ <https://ai4grids-symposium.htwg-konstanz.de/de>

5. KNN-Regler zur Betriebsführung (HTWG Konstanz)
6. Entwicklung eines KI-Gesamtalgorithmus (HTWG Konstanz)

Im Folgenden werden die Ergebnisse der von Fraunhofer ISE behandelten Punkte 1, 2, 3 dargestellt.

1.2.1 Topologie-Erkennung der Netzstruktur

Für einen belastungsabhängigen Betrieb von Nieder- und Mittelspannungsnetzen sind korrekte Netzdaten erforderlich. Netzdaten bei Verteilnetzbetreibern sind vor allem für die letzte Meile, die Niederspannungsebene, nicht hinreichend digitalisiert. Es fehlen also teils Betriebsmittel in der Geodatenbank oder Anschlüsse sind nicht exakt hinterlegt. Die GIS-Daten liefern nicht zuverlässig ein galvanisch geschlossenes Netzwerk, da nicht alle Betriebsmittel digitalisiert sind. Das Netzabbild in Leitsysteme zu integrieren, erfordert daher einen hohen manuellen Aufwand. Zudem sind Schaltzustände in der Niederspannungsebene häufig nicht digitalisiert, sodass Änderungen in der Netzstruktur im laufenden Betrieb nicht oder nur mit erheblicher Verzögerung auf das Modell übertragen werden.

Ziel des Arbeitspakets 2.3 war, diese Herausforderungen durch eine teil-automatisierte Netztopologie-Erkennung zu lösen. Dafür wurde ein Verfahren zur Synthetisierung von Niederspannungsnetzen auf Basis von öffentlich zugänglichen Daten mit Fokus auf ländliche Gebiete und Vorstädte entwickelt. Die verwendete Methodik erzeugt auf Basis graphentheoretischer Flüsse elektrische Netzwerke und stellt deren Stabilität durch kostenoptimale Wahl der Betriebsmittel sicher. Das so gewonnene synthetische Netzmodell enthält in der Regel Fehler, die auf die unzureichende Datenausgangslage zurückzuführen sind. Im zweiten Teil des Unter-Arbeitspakets 2.3 wurde darum ein Algorithmus entwickelt, der Topologiefehler erkennt und beheben kann.

Tabelle 1: Verwendete Datenklassen für die automatisierte Netztopologie-Erkennung.

Datenquelle	Daten
Ding0	• Generatordaten (Lage und Leistung). • Position der Ortsnetzstationen. • Information über die Fläche der zu bauenden Netze, da für diese Fläche eine ONS bekannt ist, wird dafür ein NS-Netz gebaut.
Open Street Map	Gebäudeinformationen, Straßen und Koordinaten, um das synthetische Netz daran zu planen.
PyPSA (Netzberechnungssoftware)	Ergebnisse der Lastflussberechnung, um auf Überlastungen im Netz zu überprüfen.
Solar Panel Calculators ²	Solar Panel Daten zur Feststellung, welche Kapazität und welche Dachfläche benötigt wird.
Lastprofile aus synGHD (am ISE entwickeltes Tool zur Erstellung synthetischer Lastprofile)	Gebäudespezifische Last- und Erzeugungszeitreihen, um Maximallasten zu bestimmen, wenn keine Daten vom Netzbetreiber vorhanden.
Zensus	Gebäudedaten (Anzahl Haushalte), um die Maximallast an einem Knotenpunkt genauer zuzuordnen.

² https://www.inbalance-energy.co.uk/articles/solar_panels_pv_calculator.html



Abbildung 3: Open Street Map Visualisierung des Gebiets von Isth. Im orangenen Bereich fehlen Gebäudedaten, daher sind dort keine Gebäude eingezeichnet.




Abbildung 2: Synthetisiertes Netz. Alle Leitungen sind blau eingefärbt, d.h. es gibt keine Leitungsüberlastungen. Alle Knoten sind grün eingefärbt, d.h. es liegen keine Spannungsbandverletzungen vor.

1.2.1.1 Topologie-Erkennung

Die Vorgehensweise des Verfahrens zusammengefasst:

1. Ein geographisches Gebiet wird ausgewählt und dient als Last-Areal. In dem Last-Areal lokalisierte Gebäude, Verbraucher und Generatoren werden aus GIS-Daten importiert und parametrisiert (siehe Tabelle 1 für die Datenquellen). Zur Parametrierung werden auf Basis der Gebäudetypen die zugehörigen Lastprofilkategorien (z.B. Bildung, Büro, Industrie, öffentliche Gebäude...) zugeordnet.
2. Auf Basis der Parametrierung kann das Last-Areal in getrennte Cluster aufgeteilt und ihr jeweiliger Lastschwerpunkt bestimmt werden. Für jeden Cluster wird ein Graph erstellt und die im Cluster enthaltenen Gebäude, Generatoren und Verbraucher über die kürzeste Distanz an die Transformatoren an dem Lastschwerpunkt angeschlossen. Dadurch entsteht eine radiale Baumstruktur.
3. Für jeden erstellten Graphen wird ein eigenes elektrisches Netz erstellt. Durch die Anwendung von Ausbaumaßnahmen ist die Einhaltung von technischen Restriktionen (keine Spannungsbandverletzungen oder Leitungsüberlastungen) sichergestellt.

Das Verfahren wurde evaluiert anhand realer Daten und ausgewählter Testnetze der Gemeinden Friedrichshafen, Frickingen, Tussenhausen und Isth als ländliches Testgebiet.

Als Key Performance Indicators (KPIs) für die Qualität der synthetisierten Netze kommen grundsätzlich in Frage:

- die gesamte Leitungslänge,
- Anzahl verbauter Transformatoren,
- Typ verbauter Transformatoren und
- Typ verwendeter Leitungsquerschnitte.

Aufgrund oftmals ungenügender Daten über verwendete Leitungsquerschnitte und Trafostufungen ist ein Vergleich nicht immer vollständig möglich. Auch wurden zur Erstellung der synthetischen Netze nur je drei Leitungstypen und Transformatortypen verwendet.

Tabelle 2 zeigt die Ergebnisse des Vergleichs für die Leitungslänge. Für Frickingen gab es keine öffentlichen Angaben zu den Leitungslängen. Die größere Abweichung für das Netz Friedrichshafen stammt daher, dass sehr viele große Lasten im Netz angenommen wurden, welche normalerweise an das Mittelspannungsnetz angeschlossen sind. Um die technischen Restriktionen einzuhalten, hat der Algorithmus zusätzliche parallele Leitungen verlegt.


Tabelle 2: Vergleich der Leitungslängen in synthetischem und originalem Netz.

Netz	Originale Leitungslänge [km]	Synthetische Leitungslänge [km]	Abweichung [%]
Friedrichshafen	1116,1	1800	61
Tussenhausen	46,91	48,51	3,4
Istha	19,47	19,61	0,71

Tabelle 3: Vergleich der KPIs für Schnetzenhausen E212.

KPIs	Originalnetz	Synthetisiertes Netz
Leitungslänge gesamt [m]	5143	4462
Transformortyp	0.63 MVA 20/0.4 kV	0.25 MVA 20/0.4 kV und 0.63 MVA 20/0.4 kV
Anzahl Transformatoren	1	2
Anzahl Netzanschlusspunkte	90	112

Die Qualität der Ergebnisse des Verfahrens hängen von der Qualität der öffentlich verfügbaren Daten ab. In Open Street Maps gibt es beispielsweise Netzabschnitte, in denen keine Gebäude hinterlegt sind, obwohl dort Gebäude existieren (siehe Abbildung 3). Da die Erstellung der Netze auf der Bildung von Cluster über Lastschwerpunkte basiert, ist eine gute Datengrundlage über vorhandene Lasten und Generatoren im Netz nötig, um das synthetische Netz passend zu erzeugen. Die Ergebnisse für ein weiteres Testnetz sind in Tabelle 3 zusammengefasst.

**Abbildung 4: Projektpartner Stadtwerke am See liefert Netzdaten als shapefiles (grau schattierte Flächen).**

Neben quantitativen Werten wie der Leitungslänge wurden auch topologische Eigenschaften des Netzmodells verglichen, wie z.B. die korrekte Platzierung von Transformatoren. Die synthetisch erzeugten Netze liegen als PyPSA-Netzmodell vor, wobei die originalen Netzdaten als Shapefiles vorliegen (Abbildung 4). Die Entwicklung eines Übersetzungstools, welches Shapefiles zu einem PyPSA-Modell automatisiert transformieren kann, war im Rahmen des Projekts nicht möglich. Stattdessen wurde der umgekehrte Weg

gewählt und die synthetisch erzeugten Netze als Shapefiles dargestellt. So konnten die Netztopologien über QGIS mit einer hinterlegten OpenStreetMap Karte verglichen werden. Dabei konnten einige Fehlerquellen analysiert und Ergebnisse verbessert werden:

- Gebäude wurden durch den Algorithmus fälschlicherweise als Netzanschlusspunkte erkannt (z.B. sehr kleine Gebäude wie z.B. Garagen, die in der Realität nicht separat am Netz angeschlossen sind).
- Wege wurden nicht erkannt und somit nicht verwendet, um Leitungen zu verlegen. Grund dafür sind fehlende oder veraltete Daten aus den öffentlichen Quellen.
- In zusammenhängenden Gebäudegruppen wurden Gebäude einzeln angeschlossen, obwohl nur manche oder nur ein Gebäude einen Netzanschlusspunkt hat.
- Die Anzahl der installierten Transformatoren unterschied sich.

In Abbildung 5 **Fehler! Verweisquelle konnte nicht gefunden werden.** ist beispielsweise zu erkennen, dass der Transformator nahe dem tatsächlichen Standort aber leicht versetzt angenommen wurde. Die Platzierung der Transformatoren findet im Algorithmus nach Lastschwerpunkt statt. Im realen Netz sind die Transformatoren teilweise an Stellen verbaut, zu denen der Algorithmus keine Wege erkannt hat (diese sind nicht in den öffentlichen Daten hinterlegt bzw. existieren nicht). Somit ist es teilweise nicht möglich, die Transformatoren mit Hilfe von synthetischen Verfahren exakt zu platzieren.

Außerdem werden manche Gebäude im synthetischen Netz angeschlossen, obwohl dies in den Originaldaten nicht der Fall ist. Zudem sind manche Hausanschlüsse nicht an die korrekte Leitung angeschlossen, sondern an die Leitung der parallel verlaufenden Straße. Grund dafür ist, dass Netzknoten für Gebäude an Gebäudemittelpunkte gesetzt werden. Da der Algorithmus immer die nächstgelegene Leitung als Anschlusspunkt nimmt, können diese Fehler auftreten.




Abbildung 5: Netzgebiet Spaltenstein dargestellt in QGIS mit einer Karte von OpenStreetMap als Hintergrund. Links das synthetisch erstellte Netz. Rechts das originale Netz. Der Transformator ist im Modell leicht abweichend platziert.

1.2.1.2 Automatisierte Korrektur von Fehlern in der Verteilnetztopologie

Im Projekt wurde ein Algorithmus zur automatisierten Fehlererkennung in Verteilnetztopologien entwickelt. Ziel war es, ein auf Graphen spezialisiertes Neuronales Netzwerk zu trainieren, um anhand von Messdaten intelligenter Stromzähler (Smart Meter) Verteilnetztopologien zu verifizieren und gegebenenfalls zu korrigieren. In einem ersten Schritt wurde die prinzipielle Anwendbarkeit der Methode bei bestmöglicher Datenverfügbarkeit und -qualität bewiesen. Im zweiten Schritt wurden die technische Qualität des Algorithmus verbessert und realistischere Randbedingungen untersucht.

Methodik

Die Topologie eines Verteilnetzes umfasst u.a. Anschlusspunkte, Kabelverläufe und Schaltzustände. Auch wenn die Anschlusspunkte dem Netzbetreiber bekannt sind bzw. im synthetischen Netz gut lokalisiert werden, bleiben als häufige Fehlerquellen noch falsch vermutete Kabelverläufe und falsch abgespeicherte Schaltzustände. Galvanisch lassen sich Schaltzustände jedoch auch als Kabelverläufe verstehen, weshalb unsere Arbeit sich zunächst auf Kabelverläufe konzentrierte. Denkbar ist eine Ausweitung der Methode auf die Korrektur von Netzparametern wie Leitungswiderstand.




Abbildung 6: Schematische Darstellung der Klassifizierung.

Gegeben eine (reale oder synthetische) Netztopologie, gilt für jeden Anschlusspunkt: Entweder er ist in der Realität genau mit den eingezeichneten Nachbarn verbunden (Klasse 0) oder nicht (Klasse 1). Ein Graph Neuronales Netzwerk (GNN)³ ist in der Lage, diese binäre Entscheidung für jeden Anschlusspunkt automatisiert zu treffen. Abbildung 6 veranschaulicht die Klassifizierungsaufgabe. Als Input erhält das GNN einerseits Messdaten, andererseits entsprechend der Netztopologie galvanisch erwartete Werte.

Zusammenfassen lässt sich die Datenverarbeitung in vier Schritten (Abbildung 7):

1. Darstellung einer Netztopologie mit Messreihen in PyPSA.
2. Ermittlung der erwarteten Messdaten mittels Zustandsschätzung oder Lastflussberechnung.
3. Klassifikation der Netzknoten mittels vortrainiertem GNN.
4. Verifikation der Netztopologie, ggf. Korrekturvorschlag.

Als Performance-Maße wurden Precision, Recall und F1-Score der trainierten Modelle aufgezeichnet. Diese Maße kombinieren Falsch-Positive (FP), Falsch-Negative (FN), und Richtig-Positive (RP) (Tabelle 4).

³ Verwendet wurde ein GATv2 basiertes Modell mit drei Schichten.




Abbildung 7: Veranschaulichung der vier Verarbeitungsschritte unserer Methode.

Um das GNN auf das Problem anzupassen, wird es zuvor mit synthetischen Messreihen trainiert. Dabei wird dem Modell eine galvanische Momentaufnahme des Netzes präsentiert, die es hinsichtlich möglicher Fehler klassifizieren soll. Macht das Modell dabei Fehler, wird es mit Hilfe eines Gradienten-Verfahrens verbessert. Mittels eines hinreichend großen Datensatzes und einer ausreichend hohen Anzahl von Durchgängen wird das Modell hinsichtlich seiner Klassifikationsaufgabe auf diese Weise optimiert. Unser Datensatz umfasst 2 reale und 4 Netztopologien, von denen jeweils 30-150 fehlerhafte Varianten erzeugt wurden. Mit 4 Zeitschritten pro Variante umfasst unser Datensatz 840 Momentaufnahmen.

Da Niederspannungsnetze unterschiedlich komplex sein können, wird das GNN mit Cross-Validation trainiert. Das heißt, dass das GNN nicht immer auf den gleichen Netztopologien trainiert wird. Stattdessen wird es mit den Momentaufnahmen der Varianten von 4 von 6 Netztopologien trainiert. Die übrigen beiden werden für die Validierung herangezogen. Damit ergeben sich 15 mögliche, sogenannte Cross-Validation-Splits.

Tabelle 4: Übersicht Performance-Maße.


Maß	Formel	Deutung
Precision	$P = \frac{RP}{RP + FP}$	Wenn das Modell einen Knoten als fehlerhaft markiert, mit welcher Wahrscheinlichkeit ist er tatsächlich fehlerhaft?
Recall	$P = \frac{RP}{RP + FN}$	Welchen Anteil aller fehlerhaften Knoten im Datensatz kann das Modell entdecken?
F1-Score	$F1 = 2 \frac{P \cdot R}{P + R}$	Harmonisches Mittel von Precision und Recall.

Ergebnisse

Die Methode ist geeignet, in PyPSA vollständig modellierte Niederspannungsnetze auf Topologiefehler zu untersuchen. Unter idealen Bedingungen, d.h. wenn für das Niederspannungsnetz sämtliche Phasenwinkel und Spannungsamplituden zu einem Zeitpunkt bekannt sind, findet unser Modell Fehler mit hoher Precision (Median=0.9) und akzeptablen Recall (Median=0.6).

Auch wurde das messtechnisch realistischere Szenario untersucht, in welchem uns der Phasenwinkel für die Analyse der Netztopologie nicht zur Verfügung steht. Überraschenderweise wird die Performance dadurch im Schnitt nicht beeinträchtigt (Abbildung 8).

Schließlich wurde getestet, wie sich das Modell unter Rauschen und realistischer Datenverfügbarkeit verhält. Während das Rauschen von Neuronalen Netzwerken gewöhnlicherweise gut aufgefangen werden kann, stellt das Fehlen von Smart Metern in der Niederspannungstopologie eine größere Herausforderung dar. Zukünftige Arbeiten betrachten einen Ansatz, bei dem fehlende Werte durch Schätzwerte ersetzt werden sollen.

**Abbildung 8 Vergleich: Performance mit und ohne Phasenwinkel.**

1.2.2 Lokalisieren von neuen Netzteilnehmern

Besonders in den Niederspannungsnetzen sind eine Vielzahl Anschlüsse von Teilnehmern mit einer hohen Anschlussleistung vorhanden und es kommen fortlaufend neue hinzu. Hierzu zählen PV-Anlagen oder Wärmepumpen, die im Rahmen der Energiewende zugebaut werden und aufwändig in Registern sowie Datenbanken nachgepflegt werden. Zusätzlich gibt es neue Netzteilnehmer wie Elektrofahrzeuge, wo die Ladeinfrastruktur dem Netzbetreiber zwar bekannt ist, die Fahrzeuge aber ihren Anschlusspunkt wechseln. Da alle genannten Einheiten eine große Anschlussleistung aufweisen, können sich deren Netzanschlüsse kritisch auf die Netzstabilität auswirken.

Im Projekt wurden Methoden des maschinellen Lernens verwendet, um die räumliche Verteilung und das Lastprofil von Verbrauchern mit hoher Anschlussleistung zu ermitteln. Da nicht ausreichend Messdaten zur Verfügung standen, wurden synthetische Lastgänge verwendet. Dafür wurden mit dem Fraunhofer-Werkzeug synPRO⁴ Zeitreihen in einer zeitlichen Auflösung von 5 Minuten über ein Jahr für 15 Wohngebäude mit unterschiedlicher Anzahl an Bewohnern und unterschiedlicher Anzahl an Elektrofahrzeugen simuliert. Die möglichen Ladeleistungen an den einzelnen Gebäuden sind 3,7 kW, 7,2 kW oder 11 kW.

Als Ansatz wurde Non-Intrusive Load Monitoring verfolgt. Hierbei werden aus der Zeitreihe eines Hauptzählers die Zeitreihen der Unterzähler extrahiert, und der Hauptzähler entweder als Zähler am Hausanschluss oder an einem Trafo angenommen. Dieses Verfahren ist auch als Disaggregation von Energiedaten bekannt. Seit den 1980er Jahren wird zu diesem Thema geforscht; in den letzten Jahren vermehrt mit Deep Learning Ansätzen. Eine Sammlung von Disaggregationsalgorithmen sind als Open Source Software in den Paketen nilmtk⁵ und nilmtk-contrib⁶ verfügbar, welche in diesem Projekt verwendet wurden.

Die zeitliche Auflösung der synthetischen Zeitreihen ist mit 5 Minuten deutlich gröber als die in der Literatur üblicherweise betrachteten Zeitreihen. Um die Eignung der Algorithmen aus dem nilmtk-Paket für die synthetischen Daten zu überprüfen, wurden zunächst die Algorithmen aus dem zugrundeliegenden Paper⁷ auf die synthetischen Zeitreihen und auf die Zeitreihe der fünf Minuten-Mittelwerte des UK-DALE 8 Datensatzes angewandt. Aus Gründen der Vergleichbarkeit wurden Elektrofahrzeuge und Wärmepumpen nicht berücksichtigt. Das Training wurde auf den ersten 9 Monaten des Jahres durchgeführt, das Testen auf den restlichen 3 Monaten. Zur Vermeidung von Overfitting wurde im Training ein early stopping eingebaut.

Da Smart Meter Daten in 15 Minuten Abständen erhoben werden, wurde das gleiche Experiment auch mit 15-Minuten-Mittelwerten durchgeführt. In beiden Fällen schnitt der Sequence-to-Point-Algorithmus am besten ab, weshalb im weiteren Verlauf der Sequence-to-Point-Algorithmus verwendet wurde. Insgesamt waren die Ergebnisse bei höherer zeitlicher Auflösung besser, was mit der größeren Anzahl an Daten erklärt werden kann. Durch Anpassung der Menge an Trainingsdaten wurde die Performance bei beiden Auflösungen wieder ähnlich. Eine Erhöhung der Frequenz der Smart Meter Messung könnte also für die Detektion von einzelnen Verbrauchertypen oder bei wenigen vorhandenen Daten von Vorteil. Ein genereller Vorteil der höheren Frequenz wurde aber nur bei gleicher Trainingsperiode und somit deutlich mehr Trainingsdaten erzielt. Da die aktuelle Frequenz von Smart Meter Messungen 15 Minuten beträgt, wurde im weiteren Projektverlauf mit dieser Auflösung gearbeitet.

Im nächsten Schritt wurden die Lastgänge der Elektrofahrzeuge je Gebäude mit Sequence-to-Point aus dem Hauptzähler disaggregiert. Dabei sind die Ergebnisse besser, je größer der Anteil des

⁴ <https://synpro-lastprofile.de/>

⁵ <https://github.com/nilmtk/nilmtk>

⁶ <https://github.com/nilmtk/nilmtk-contrib>

⁷ Batra et al., "Towards reproducible stat-of-the-art energy disaggregation", in *Proc. 6th ACM Int. Conf. Syst. Energy Effic. Build. Cities Transp.*, 2019, pp. 193-202.

⁸ Verfügbar unter <https://jack-kelly.com/data/>




Abbildung 9: Tatsächliche Ladeleistung im Vergleich zum Ergebnis des Sequence-to-Point-Algorithmus.

Elektrofahrzeuges am Gesamtbedarf ist. In Abbildung 9 ist als Beispiel das Ergebnis der Disaggregation nach dem Elektrofahrzeug eines Hauses mit 3,7 kW Ladeleistung zusammen mit der synthetischen Zeitreihe der Ladevorgänge visualisiert. Die Ladevorgänge werden gut abgebildet, allerdings werden die Spitzenlasten oft unterschätzt. Es wurden Genauigkeiten zwischen 97,2 % und 99,8% erreicht.

Danach wurde das eingesetzte Repertoire von Algorithmen um Transformer ergänzt, welche zurzeit zum State of the Art in Deep Learning zählen. Zum Einsatz kam der BERT-Algorithmus (Bidirectional Encoder Representation from Transformers) von welchem es eine Implementierung in nilmk-contib gibt, welche aber nicht in dem Referenzpaper betrachtet wurde. Es konnten gegenüber der Standardimplementierung im nilmk-cotrib-Paket Verbesserungen in der Laufzeit und in der Genauigkeit erzielt werden. Die Erkennung von Elektrofahrzeugen konnte mit dem BERT-Algorithmus nicht verbessert werden. Danach wurden die Wärmepumpenzeitreihen auch berücksichtigt. Diese Veränderung resultierte wie erwartet in einer Verschlechterung in der Erkennung von Elektrofahrzeugen. Es wurden mehrere Ansätze verfolgt, um Verbesserungen zu erreichen.

Die Algorithmen wurden in Multi-Input-Modelle umgewandelt, damit Wetterdaten als zusätzliche Inputzeitreihe genutzt werden können. Die zugrundeliegende Idee ist, dass durch Kenntnis der Außentemperatur Wärmepumpen besser erkannt werden können. Dieser Ansatz resultierte in einer durchschnittlichen Verbesserung von 11% für die Erkennung von Wärmepumpen und 16% in der Erkennung von Elektrofahrzeugen.

Im nächsten Schritt wurden die Modelle zu Multi-Output-Modellen erweitert, welche gleichzeitig Elektrofahrzeuge und Wärmepumpen erkennen können. Die Ergebnisse waren durchschnittlich 10% schlechter für Wärmepumpen und 7,5% schlechter für Elektrofahrzeuge. Je nach Fragestellung könnte dieser Ansatz trotzdem von Nutzen sein, da nur ein Modell anstatt zweier Modelle trainiert werden muss, was je nach Hardwareressourcen die Laufzeit verringert.

Um die Übertragbarkeit der Modelle auf ungesehene Daten zu testen, wurden zwei Experimente durchgeführt. Zunächst wurde ein Modell auf einem synthetischen Haushalt trainiert und auf einem ähnlichen Haushalt eingesetzt. Dadurch wurden die Fehler 30% größer sowohl für Wärmepumpen als

auch für Elektrofahrzeuge. Bei den Elektrofahrzeugen konnte beobachtet werden, dass insbesondere die Fahrzeuge mit kleiner Ladeleistung (3,7 kW) schlecht erkannt wurden, bei größeren Ladeleistungen waren die Ergebnisse besser.

Auch der Einsatz vortrainierter Modelle auf realen Messdaten wurde untersucht, wobei der Open Source Datensatz Pecan Street Dataport⁹ genutzt wurde. Dabei wurde auf neun Monaten trainiert und auf drei Monaten getestet. Es konnte keine klare Verbesserung erreicht werden. Erklärbar ist das damit, dass die Datensätze zu unterschiedlich sind. Den synPRO Daten liegen deutsche Statistiken zugrunde, aber die Pecan Street Dataport Daten stammen aus den USA.

Nachdem auf Haushaltsebene gute Ergebnisse erzielt werden konnten, wurden die Algorithmen auf der Netzebene eingesetzt. Die Detektion von Wärmepumpen funktionierte ähnlich gut wie auf Haushaltsebene; die Erkennung von Elektrofahrzeugen verlor ein paar Prozentpunkte.

1.2.3 Netzzustandsschätzung

Verteilnetze sind in der Regel nicht vollständig beobachtet – voraussichtlich auch nach dem Ausbau von intelligenten Messsystemen nicht. Für einen knotenscharfen und belastungsabhängigen Netzbetrieb müssen die nicht beobachteten Netzknoten abgeschätzt werden. Dies gewinnt insbesondere durch die Umsetzung von EnWG §14a neue Bedeutung. Durch die hohe Anzahl Knoten und geringe Messstellendurchdringung stoßen Schätzer wie Weighted Least Squares (WLS) schnell an ihre Grenzen. Der Einsatz von KI-Methoden ermöglicht hier neue Möglichkeiten.

1.2.3.1 Modell

Zu Beginn des Projekts wurde in einer Literaturrecherche bereits bestehende KI-Ansätze zur Zustandsschätzung in Verteilnetzen anhand der folgenden Kriterien verglichen:

- **Wenige Messungen:** Der Algorithmus soll trotz sehr weniger Messstellen (wie im Verteilnetz derzeit üblich) gute Schätzungen von Spannung und Strom ermöglichen und so einen Mehrwert gegenüber den deterministischen Algorithmen bieten.
- **Flexibler Dateninput** (zum Beispiel Leistungsmessungen, Metadaten wie Gebäudetypen und Strukturinformationen über die Netztopologie) und somit Nutzung möglichst vieler verfügbarer Daten, um den Trainingsprozess zu verbessern.
- **Neue Netztopologien:** Das entwickelte Verfahren zur Zustandsschätzung soll auf beliebige Verteilnetztopologien (welche nicht im Training des KI-Algorithmus verwendet wurden) angewendet werden können.
- **Netzänderungen:** Der Algorithmus soll gegenüber kleineren Topologieänderungen (beispielsweise Ausfälle einer Leitung, Schaltzustandsänderung) robust funktionieren, ebenfalls ohne das Verfahren für jede Schalterstellung erneut zu trainieren.
- **Echtzeit Monitoring:** Aufgrund zunehmender fluktuierender Erzeuger und Verbraucher im Verteilnetz können kurzfristig Überlastungen im Netz entstehen. Um schnellstmöglich auf diese Überlastungen im Verteilnetz zu reagieren, soll das Verfahren kurze Rechenzeiten haben.

Die Entscheidung fiel auf Graph Neural Networks (GNNs). Ausschlaggebend war unter anderem ihr Alleinstellungsmerkmal, die Netztopologie (Struktur-Information) erfassen zu können. GNNs nutzen diese Informationen im Trainingsprozess aus, um strukturelle Zusammenhänge und Netzinformationen zu verbinden. Diese Informationen werden an das GNN über sogenannte Knoten- und Kanteninformationen übergeben (Abbildung 10). Knoteninformationen können zum Beispiel Messwerte aus Smart Metern sein oder andere Metainformationen wie Gebäudetyp, installierte PV-Anlagen oder vorhandene Elektrofahrzeuge beinhalten. Kanteninformationen beschreiben die physikalischen Parameter einer Leitung oder eines Transformators.

⁹ <https://www.pecanstreet.org/dataport/>




Abbildung 10: Beispiel Daten-Input und -Output des Graph Neural Networks.

Im Gegensatz zu anderen KI-Verfahren sind GNNs außerdem in der Lage, für eine Verteilnetz-Topologie trainiert zu werden und auf neuen Netztopologien angewendet zu werden. Die Art der Informationsverarbeitung und die Fähigkeit auf Netztopologien zu generalisieren, machen GNNs zu einer vielversprechenden KI-Lösung für die Zustandsschätzung im Verteilnetz. Das Neuronale Netz wird mit der Python Toolbox „Pytorch Geometric¹⁰ (PyG)“ erstellt, welche speziell für die Anwendung von GNNs entwickelt wurde.

Innerhalb der Klasse von GNNs wurden „Graph Attention Networks“ verwendet. Diese weisen den Nachbarknoten eines Netzknotens Gewichtungen zu, je nach Wichtigkeit und Einfluss der Knoteninformationen auf die am Netzknoten zu schätzenden Werte.

1.2.3.2 Daten

Für das Training des Zustandsschätzers standen reale Messungen von Netzgebieten der Projektpartner zur Verfügung. Nach Analyse der Eingangsdaten zeigte sich aber, dass zusätzliche synthetische Trainingsdaten notwendig sind, um im GNN-Training Overfitting zu vermeiden. Gleichzeitig konnte so eine umfassendere Validierung der Ergebnisse ermöglicht werden.




Abbildung 11: Allensbach Netzscenario 2022.

Für die Erstellung synthetischer Daten wurde ein Netzscenario-Generator weiterentwickelt, welcher für vorgegebene Zieldurchdringungen von PV-Anlagen und Elektrofahrzeugen im Netz randomisiert PV-Anlagen und E-Ladesäulen in einem Netz verteilt und Last- und Erzeugungszeitreihen entsprechend zuordnet. Dazu werden synthetische Lastprofile verwendet, die mit dem am Fraunhofer ISE entwickelten Lastprofilgenerator *synPRO*¹¹ erzeugt wurden. Mit dem Szenario-Generator konnten so beliebig viele Netzscenarioen und Lastfälle erstellt werden, welche als Trainings- und Testdaten für die KI-Algorithmen in einer owncloud gesammelt und mit den Projektpartnern geteilt wurden. Konkret wurden GIS-Daten eines Netzgebietes der „Stadtwerke am See“ in ein PyPSA Netzmodell übersetzt (Abbildung 11). Dazu wurden Methoden des in AP 2.3 (Topologieerkennung) entwickelten Verfahrens verwendet.

¹⁰ <https://pytorch-geometric.readthedocs.io/en/latest/>

¹¹ <https://ies03.ise.fraunhofer.de/synpro/>




Abbildung 12: Verteilung der echten und geschätzten Spannung (links) und Phase (rechts).

Eine Kernaufgabe dieser Arbeit bestand in der Entwicklung eines Software-frameworks für das automatisierte Einlesen und Vorverarbeiten der Netzdaten aus PyPSA und der Export hin zu Graph-Objekten im PyTorch-Datenformat für die weitere Verwendung im GNN. Eine Herausforderung bestand darin, Knoten- und Kanteninformationen in einen standardisierten Datensatz zu kombinieren, wenn die Anzahl Knoten und Dimensionalität der verfügbaren Messgrößen von Netz zu Netz unterschiedlich ausfallen. Hier boten sich sogenannte heterogene Datenstrukturen als Lösung an. Im Gegensatz zu früheren Arbeiten mit homogenen Modellen erlauben heterogene Graph Neural Networks durch Definition unterschiedlicher Knoten- oder Kantentypen die Nutzung variabler Eingangsdaten. Dadurch wird die Nutzung möglichst vieler verfügbarer Daten verschiedenster Datentypen ermöglicht.

1.2.3.3 Auswertung

Wir definieren das Gütekriterium für eine Schätzung wie folgt: Ein geschätzter Wert wird als korrekt bezeichnet, wenn die absolute Differenz zwischen Original und Schätzwert um weniger abweicht als ein Grenzwert. Konkret wurde für die Spannung ein Grenzwert von 0.001 p.u. (0.4 V) und für die Phase 0.01 rad (0.57°) angenommen.

Trainiert wurde das GNN für 70% der Zeitpunkte eines Testnetzes mit Last- und Erzeugungszeitreihen für ein Jahr in 15-minütiger Auflösung. Validiert wurde das Training an den restlichen 30% der nicht verwendeten Zeitpunkte. Die erreichte Genauigkeit beschreibt den Prozentsatz der Werte, die unter den oben definierten Grenzwerten liegen. Für ein Beispielnetz mit 18 Knoten sind die Ergebnisse in Abbildung 12 und Abbildung 13 dargestellt. Insgesamt wird eine Schätzgenauigkeit von 90% erreicht.




Abbildung 13: Zeitreihe der Spannung im Verlauf einer Woche. Der grau schattierte Bereich bezeichnet die maximal zulässige Abweichung des Schätzwerts vom echten Wert.

Tabelle 5: Zusammenfassung der Ergebnisse von AP 2.


Ergebnis / Meilenstein Nr.	Erzieltes Ergebnis	Erreicht am	Kommentar zur Einhaltung des Zeitplans
MS 5	KI-Algorithmen optimiert und robust	06.2023	Der Zeitplan konnte eingehalten werden.

1.3 AP 3: Test der Algorithmen in Laborumgebung

1.3.1 Test der einzelnen Algorithmen im Digital Grid Lab ISE

Der Meilenstein 3.1 (Proof-of-Principle Einzelalgorithmen im Labor) wurde für den in AP2.5 entwickelten Algorithmus erreicht, wie im Folgenden gezeigt. Die Algorithmen aus AP 2.3 und AP 2.4 sind keine Echtzeitanwendungen und eine Simulation in Laborumgebung daher nicht notwendig. Erste Tests der in AP 2.5 entwickelten Zustandsschätzung wurden bei dem Projekttreffen im März 2022 am Fraunhofer ISE im Digital Grid Lab durchgeführt. Dazu wurde ein Beispielnetz mit insgesamt 4 Lastknoten in Typhoon modelliert. Leistungsmessungen wurden mit den HIL (Hardware in the Loop) Computern in Echtzeit simuliert.

Um die in Typhoon simulierten Messwerte an die AI-Leitwarte und somit den Algorithmus zur Zustandsschätzung zu übertragen, wurde eine REST API als Schnittstelle verwendet (Abbildung 14). Die Tests haben gezeigt, dass die Datenübertragung über die Schnittstellen funktioniert. Bei laufender HIL-Simulation werden die aktuellen Leistungswerte (Nenn- und Blindleistung) aus dem Netzmodell über die REST API an die AI-Leitwarte gesendet. Auf Grundlage dieser Leistungen ergibt eine Zustandsberechnung die Spannungen, welche im Netz anliegen müssten. Die geschätzten Spannungen werden zurück an die HIL-Simulation geschickt, sodass sie dort mit den tatsächlich vorliegenden Spannungen validiert werden können.

**Abbildung 14: Erster Testablauf der GNN-Zustandsschätzung im Digital Grid Lab.**

Am 14.12.2022 fand ein Workshop des Teams zur Algorithmus-Entwicklung im Digital Grid Lab statt. Das in Abbildung 15 abgebildete Modell eines Wohngebiets in Allensbach wurde als Testnetz verwendet, um die gesamte Ablaufkette des Betriebsführungsalgorithmus zu testen. Dabei wurden die in Echtzeit simulierten Messwerte des Typhoon-Modells über ein Modbus an den Algorithmus übergeben und in das entsprechende PyPSA-Netzmodell geschrieben. Anhand der Tests konnten fehlerhafte Stellen innerhalb des Codes der Zustandsschätzung erkannt und beseitigt werden.

1.3.2 Test des Gesamt KI-Algorithmus im Digital Grid Lab ISE

Im AP3.2 ging es darum, eine möglichst realitätsnahe Simulationsumgebung zu schaffen, an welcher einzelne und schließlich der gesamte Algorithmus getestet werden können. Dafür wurde die Hardware-in-the-Loop Infrastruktur im Digital Grid Lab des Fraunhofer ISE genutzt. Mit dem *PyPSA2Typhoon Konverter* und einigen händischen Anpassungen wurde das Demonstrationsnetz Allensbach in ein echtzeitfähiges Typhoon HIL-Modell übertragen (s. Abbildung 15).




Abbildung 15: PyPSA2Typhoon erstellt ein Typhoon Modell anhand eines PyPSA Netzmodells. Die Netzstruktur wird bei vorhandenen Koordinaten berücksichtigt.

Um eine stabile Simulation zu ermöglichen, musste das Typhoon Modell über einige Iterationen etwas vereinfacht werden, sodass schließlich nicht mehr an jedem Netzknoten je eine Haushaltslast, sowie eine PV-Anlage als einzelne Komponenten angeschlossen sind, sondern eine residuale Last (s. Abbildung 16 und Abbildung 17). Die beiden größten Photovoltaik-Anlagen von den Mehrfamilienhäusern 7 und 8 werden als separate Einspeiser modelliert und nicht zur Residuallast mit den Haushaltsbezügen verrechnet. Allerdings werden auch sie durch eine "Variable Last"-Komponente repräsentiert, sodass direkt vorgegeben werden kann, wieviel Leistung jede PV-Anlage zu einem bestimmten Zeitpunkt einspeisen soll. An jedem Netzknoten wird die der Realität entsprechenden Anzahl an Messpunkten simuliert.




Abbildung 16: Der Netzknoten eines Haushaltes wird im Typhoon-Modell durch eine „Variable Last“-Komponente repräsentiert.




Abbildung 17: Die Last-Komponente summiert Leistungsbezug und PV-Erzeugung zu einer Residuallast am Anschlusspunkt des Haushaltes.

Über eine grafische Oberfläche, SCADA Panel genannt, lässt sich das Verhalten des modellierten Systems während der laufenden Simulation beobachten und teilweise steuern (s. Abbildung 18).




Abbildung 18: SCADA Panel zur Beobachtung der Simulation inkl. per Modbus ausgetauschter Signale (rechts, Zoom s. Abbildung 19).




Abbildung 19: Graphen, welche die beim Modbus Client ankommenden Leistungsmessungen veranschaulichen.

Im Gegensatz zum ersten Test der einzelnen Algorithmen (s. 1.3.1) wurde für den Test des Gesamt-Algorithmus zum Datenaustausch zwischen Typhoon Modell und der Leitwarte, in welcher der Betriebsführungsalgorithmus ausgeführt wird, der Modbus-TCP-Standard verwendet. Dieser ist nicht nur schnell und leicht zu konfigurieren, sondern wird im Energiesektor tatsächlich häufig eingesetzt, sodass dies gut in den Projektkontext passt. Dabei fungiert das Modell als Server, der die in Echtzeit simulierten Messwerte (Wirk-, Blind-, Scheinleistungen und Strangspannungen der drei Phasen A, B und C am Anschlusspunkt der Haushalte an das öffentliche Stromnetz, sowie Ströme, Spannungen und Leistungen am Niederspannungstransformator) zur Verfügung stellt (s. Abbildung 20). Die Niederspannungs-

Leitwarte als Client ruft diese ab und verarbeitet sie weiter. Basierend auf den Messwerten schätzt der Algorithmus den Zustand des Netzes. Die Schätzspannungen für jeden Netzknotenpunkt können zur Validierung wieder über Modbus an das Typhoon-Modell zurückgesandt werden. Ebenfalls in Richtung Modell verschickt werden kann ein Schaltsignal an den Trafo, um dessen Spannungen stufenweise anzupassen, wenn der Algorithmus dies als notwendig erachtet.




Abbildung 20: Modbus-Server-Komponente im Typhoon HIL-Modell.

Über ein Makro im SCADA Panel ist es möglich, Zeitreihen von Haushaltslasten und PV-Erzeugungsleistungen auszulesen und diese Werte in der Simulation zu verwenden, sodass die Erzeugungen und Verbräuche kontinuierlich verändert werden. Wenn jeder Zeitschritt von 15 Minuten in der Simulation beispielsweise auf 10 Sekunden beschleunigt wird, kann somit der Netzbetrieb über z.B. ein Jahr innerhalb von etwa 100 Stunden durchgespielt werden.

Der finale Test des Gesamtalgorithmus mit dem Typhoon-Modell konnte nicht mehr innerhalb der Projektlaufzeit durchgeführt werden. Die Arbeit daran wurde danach fortgesetzt. Am 28.06.2024 wurde schließlich das Zusammenspiel der vier Module („power_flow“, „probabilistic_forecast“, „photovoltaic_forecast“, „gnn_grid_control“, zur Beschreibung siehe Berichte der Projektpartner), aus welchen sich der Gesamtalgorithmus zusammensetzt, und der HIL-Simulation abschließend getestet. Die Abbildung 21, 22 und 23 zeigen Screenshots zum Versuch. Durch das Abfahren einer Zeitreihe mit Last- und Erzeugungswerten für das Jahr 2022 werden Ein- und Ausspeiseleistungen der Haushalte und ihrer PV-Anlagen im Tagesverlauf simuliert. Im Typhoon SCADA-Panel kann beobachtet werden, welche Leistungen im aktuellen Zeitschritt vorliegen (Abbildung 21, grün umrandet). Ebenfalls angezeigt werden die Schätzspannungen an den Netzknoten, welche die Lastflussberechnung des Algorithmus ergibt (Abbildung 21, violett gestrichelt umrandet). Solange diese nahe an den Nominalwerten von 230 V liegen, muss der Regler nicht eingreifen und die Transformatorstellung bleibt unverändert (Position 0). Dies wird u.a. im Dialogfeld im unteren Teil des SCADA-Panels ausgegeben (Abbildung 21, orange gepunktet umrandet). Das Command Line-Fenster des gestarteten Algorithmus führt fortlaufend dessen Berechnungsschritte auf.

Bei sehr hohen anliegenden Lasten fallen die Spannungen im Netz ab. Darauf reagiert der GNN-Regler mit einem Schaltsignal an den Transformator (in diesem Fall Änderung von 0 auf -1), um die Netzspannung wieder anzuheben. Dies kann in Abbildung 22 beobachtet werden. Die Umschaltung der Trafo-Stellung ist im Nachhinein in der Log-Datei des Simulationsverlaufes nachvollziehbar (s. Abbildung 23).




Abbildung 21: Ausschnitt SCADA Panel mit überlagertem Command Line-Fenster während Gesamtalgorithmen-Test. Umrandet zu sehen sind aktuelle Haushalts- und PV-Leistungen (grün, durchgezogen), nach Lastflussberechnung geschätzte Knotenspannungen (violett, gestrichelt) und Schalterstellung des Trafos (orange, gepunktet).




Abbildung 22: SCADA-Panel bei Gesamtalgorithmen-Test: Wechsel der Trafo-Stellung.




Abbildung 23: In der Log-Datei der Simulation ist der Zeitpunkt des Umschaltens des Transformators auffindbar.

Tabelle 6: Zusammenfassung der Ergebnisse von AP 3.

Ergebnis / Meilenstein Nr.	Erzieltes Ergebnis	Erreicht am	Kommentar zur Einhaltung des Zeitplans
MS 2	Proof-of-Principle Einzelalgorithmen	06.2022	Der Zeitplan konnte eingehalten werden.
MS 3	Optimierung Einzelalgorithmen abgeschlossen	09.2022	Der Zeitplan konnte eingehalten werden.
MS 6	Gesamtalgorithmus auf Testsystem lauffähig	06.2024	Diese Teilarbeit konnte innerhalb der Projektlaufzeit nicht vollständig bearbeitet werden. Der MS wurde 6 Monate nach Projektende erreicht.

1.4 AP 4 Test und Demonstration in realer Umgebung

In diesem Arbeitspaket wurden die im Projekt entwickelten Algorithmen in Reallaboren getestet. Federführend war hier das ISC Konstanz; es wird auf deren Bericht verwiesen.

1.5 AP 5: Analyse technische und wirtschaftliche Potentiale

In diesem Arbeitspaket wurden die im Projekt entwickelten Technologien hinsichtlich ihres technischen und wirtschaftlichen Potentials analysiert. Federführend war hier das Stadtwerk am See; es wird auf deren Bericht verwiesen.

2. Zahlenmäßiger Nachweis

Der zahlenmäßige Nachweis erfolgt separat über die zentrale Verwaltung der Fraunhofer-Gesellschaft.

3. Notwendigkeit der Arbeit

Auch vier Jahre nach Beginn des Projekts hat sich an der Ausgangslage wenig geändert: Das Verteilnetz ist noch kaum automatisiert, und es gibt wenige Messmittel, die den Zustand des Netzes in Echtzeit übertragen können. Auch die Anzahl der installierten regelbaren Betriebsmittel wie RONTs (regelbare Ortsnetztransformatoren) o.ä. ist gering. Gleichzeitig ist mit dem Inkrafttreten des § 14a EnWG der Bedarf an Methoden zur Netzmodellerstellung, Netzzustandsermittlung und Netzsteuerung dringender denn je. Die KI-Algorithmen aus diesem Projekt legen hierfür die Grundlage.

4. Verwertbarkeit der Ergebnisse

Das Projekt liefert einen Beitrag zur Anwendung und Weiterentwicklung von KI-Methoden für die Verteilnetze und Microgrids. Ein wesentlicher Vorteil vom Einsatz künstlicher Intelligenz ist neben der Adaptionfähigkeit und erwarteten Schnelligkeit auch die geringe notwendige Rechenleistung im konkreten Anwendungsfall, da lange Optimierungsaufgaben lange im Voraus mit ausreichend Rechenzeit entwickelt wurden. Damit sollte es besser möglich sein, auf Netzänderungen unmittelbar zu reagieren. Mit der sofortigen Realnetz-Adaption geht ein direkter wirtschaftlicher Mehrwert für den Netzbetreiber einher, z.B. durch die Reduzierung von Netzverlusten und die Vermeidung manueller Anpassungen.

Das Projekt hat bereits den wissenschaftlichen Austausch durch Vorträge, Veröffentlichungen und den Besuch von Konferenzen ermöglicht. Die Zusammenarbeit mit Praxispartnern wird in Folgeprojekten fortgeführt (z.B. mit dem Stadtwerk am See in DiGO2.0).

Das Projekt baute auf dem Vorwissen der beteiligten Institute auf und diente dessen Erweiterung. So haben vier Masterarbeiten am Fraunhofer ISE zur Algorithmenentwicklung in AP 2 beigetragen. Die

gewonnenen Erkenntnisse, insbesondere zur Zustandsschätzung und Topologieerkennung, werden in Folgeprojekten (z.B. ValidateGrid) erweitert und vermehrt praxistauglich gemacht. Netzbetreiber haben in den durch das Konsortium durchgeführten Symposien reges Interesse an den im Projekt entwickelten Lösungen bekundet; das Vorhaben stieß bei allen Interessengruppen auf große Resonanz.

5. Relevante Ergebnisse von dritter Seite

Für den Berichtszeitraum sind keine relevanten FE-Ergebnisse von dritter Seite bekannt geworden. Entsprechende Recherchen sind ohne Ergebnis geblieben.

6. Erfolgte oder geplante Veröffentlichungen

Gemeinsam mit der HTWG Konstanz wurde das Paper »Probabilistic real-time grid operation management of future distribution grids with high penetration of renewable generators and electrical vehicles based on artificial intelligence« für den CIRED Workshop E-mobility and Power Distribution Systems im Juni 2022 in Porto veröffentlicht und dort in einem Postervortrag vorgestellt.

Auf dem ETG-CIRED-Workshop Innovationen im Verteilernetz am 2. und 3. November 2022 in München wurde ein Postervortrag mit dem Titel »Nutzung von Messungen und statischen Strukturinformationen zur Zustandsschätzung im Verteilernetz durch Graph Neural Networks« gehalten.

Folgende Master-Arbeiten trugen zum Erfolg des Projektes bei:

- Eric Mauß: Distribution System State Estimation using Graph Neural Networks
- Jonas Nolde: Topology Error Identification in Electrical Distribution Grids with Graph Neural Networks
- Armin Saur: Graph Neural Networks for Electrical Grid State Estimation
- Carl Wanninger: Distribution Grid Topology Error Identification with Graph Neural Networks