



Gemeinsamer Abschlussbericht
des
Forschungsvorhabens

IntegraNet II

Kontextbezogene Potenzialanalysen, Einbindung der IKT- Ebene und Untersuchung erweiterter Fragestellungen bei der integrierten Betrachtung von Strom-, Gas- und Wärmesystemen

Förderkennzeichen: 03EI1008A-B

Laufzeit: 01.11.2019-30.06.2023

Ansprechpartner: **Fraunhofer UMSICHT**
Dr. Anne Hagemeier
Osterfelder Straße 3
46047 Oberhausen
anne.hagemeier@umsicht.fraunhofer.de
+49 208 8598 1162

GWI Essen
Jörn Benthin
Hafenstr. 101
45356 Essen
benthin@gwi-essen.de
+49 201 3618-258

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages unter dem Förderkennzeichen 03EI1008 A-B gefördert.

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

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

Oberhausen/Essen, den 22.12.2023

Autoren

Jörn Benthin, Anne Hagemeyer, Annika Heyer, Dorian Höffner, Philipp Huismann, Stefanie Ruppert,
Malte Stienecker, Julian Urbansky, Paul Wolf, Marcel Bruns

Inhaltsverzeichnis

1	Einleitung.....	1
2	Modellbibliothek TransiEnt	2
2.1	Überblick über die Modellbibliothek TransiEnt	2
2.2	Weiterentwicklung der TransiEnt-Bibliothek	4
3	Elektromobilität im Verteilnetz	5
3.1	Lastprofile für Elektrofahrzeuge.....	6
3.1.1	Zielstellung der Lastprofildatenbank.....	6
3.1.2	Lastprofilerstellung.....	7
3.1.3	Validierung.....	9
3.2	Modelica-Modell ElectricCar	11
3.3	Use Case: Netzorientierter Betrieb in schwachen Niederspannungsnetzen	12
3.3.1	Szenario	12
3.3.2	Simulation.....	14
3.3.3	Auswertung	15
4	Kontextbasierter Ansatz zur Potenzialbewertung.....	18
4.1	Mögliche Aspekte eines Kontexts	18
4.2	Auswahl relevanter Merkmale	19
4.3	Anwendung der Merkmale zur Identifikation repräsentativer Kontexte mittels Clustering	20
4.4	Anwendung kontextueller Charakteristika.....	22
5	Modellierung der Regelung von Ausgleichstechnologien	23
5.1	Grundlagen/Konzepte	23
5.2	Modellierung der Regelung auf <i>GridConstructor</i> -Ebene.....	25
5.2.1	Dezentrale Einzelsystem-Regelung	26
5.2.2	Zentrale Regelung.....	27
5.2.3	Vergleich dezentraler und zentraler Regelungsansätze.....	28
5.3	Umsetzung der Regelung beim zellulären Ansatz.....	30
6	Zellulärer Ansatz zur Technologiebewertung.....	33
6.1	Grundlagen	33
6.1.1	Zellulärer Ansatz: H3-Hexagone	33
6.1.2	Machine Learning	34
6.1.3	Neuronale Netze.....	35
6.1.4	Semantische Segmentierung und Convolutional Neural Networks	39
6.2	Semantische Segmentierung von PV-Anlagen	41
6.2.1	Datenvorbereitung	42
6.2.2	Model Finding und Training.....	43
6.2.3	Anwendung und Validierung.....	46

6.3	Räumlich-energetische Charakterisierung der EE-Erzeugung	48
6.3.1	Photovoltaik	50
6.3.2	Windkraft.....	51
6.3.3	Ausbaupotenziale von Photovoltaik und Windkraft	52
6.4	Energiebedarfe	54
6.4.1	GHD-Sektor	55
6.4.2	Industrie-Sektor.....	56
6.4.3	Wohngebäudesektor	56
6.4.4	Fortschreibung Zukunftsszenarien	56
6.5	Räumlich-zeitliche Charakterisierung der Residuallasten	58
7	Modellierung von regionalbezogenen Netzinfrastrukturen	60
7.1	Datenquellen	61
7.2	Methode zur Allokation unter Berücksichtigung des unterlagerten Verteilnetzes	61
7.3	Berücksichtigung der elektrischen Netzinfrastruktur im zellulären Ansatz	64
8	Betrachtung von Strategien der Sektorenkopplung aus regionaler und infrastruktureller Perspektive	67
8.1	Szenariendefinition	67
8.2	Aufbau des Gesamtmodells.....	68
8.3	Ergebnisse und Auswertung.....	70
9	Zusammenfassung und Ausblick	77
10	Literaturverzeichnis.....	79

1 Einleitung

Das Projekt IntegraNet II baut auf den Erkenntnissen und Ergebnissen des von Fraunhofer UMSICHT und dem Gas- und Wärme-Institut (GWI) durchgeführten Projekts IntegraNet (FKZ 0324027) auf. Im Rahmen von IntegraNet wurden sowohl lokale als auch nationale Chancen und Potenziale der Sektorenkopplung erforscht. Es entstanden Modelle, die strom-, gas- und wärmebasierte Ausgleichstechnologien in verschiedenen geografischen Aggregationsstufen integrieren und die Verknüpfung von Gas- und Wärmenetzen auf unterschiedlichen Ebenen beleuchten. Ein zentraler Aspekt war die Entwicklung eines modularen Modellbaukastens für die Orts- und Verteilnetzmodellierung in Modelica, basierend auf der von der TU Hamburg im Projekt TransiEnt.EE entwickelten Modellbibliothek. Dies umfasste die Neuentwicklung von Modellen sowie die Erweiterung und Anpassung bestehender Modelle für diverse Anwendungen.

Die umfassenden Analysen des Vorgängerprojektes offenbarten, dass sich die grundlegenden Versorgungsaufgaben und Lösungsstrategien in den einzelnen Netzebenen stark voneinander unterscheiden können. Die detaillierten Modelle und Methodiken konzentrierten sich bisher auf die Orts- und Verteilnetzebene. Es konnte aber schon in diesem Kontext in verschiedenen Projekten ([EnQM](#), [IQDortmund](#), [GuStAV](#), [ResilientEE](#)) nachgewiesen werden, dass das systemische Gesamtoptimum gekoppelter Netze und Anlagen nicht der Summe der Einzelsystemoptima entspricht. Vielmehr bieten größere Anlagen- und Netzverbünde auch einen größeren Lösungsraum im Hinblick auf die Nutzung von Ausgleichsströmen, Erneuerbare Energien (EE)-Potenzialen und der Steigerung der Systemstabilität. Dieser Logik folgend ist ein starkes dezentrales System im Vorteil, wenn nicht der Kapital- und Kommunikationsaufwand und die einhergehenden Interdependenzen im selben Maße ansteigen würden und somit zwingend Teil einer detaillierten Analyse sein müssen.

Eine weitere abgeleitete Problemstellung liegt in der großen Heterogenität des gesamtdeutschen Energiesystems und dem damit einhergehenden Aufwand in der Charakterisierung und Kategorisierung repräsentativer Strukturen, sowie deren ausreichend detaillierten Modellierung. Um repräsentative regionale und überregionale Strukturen herausarbeiten und abbilden zu können, bedarf es eines Modularisierungs- und Automatisierungskonzeptes sowohl auf der Daten- als auch auf der Modellierungsseite.

Um den zuvor beschriebenen Fragestellungen Rechnung zu tragen, widmete sich IntegraNet II der Weiterentwicklung des Modell- und Methodik-Baukastens, um die Modellierung und Simulation von überregionalen sektorengekoppelten Systemen zu ermöglichen. Es wird dabei ein besonderes Augenmerk auf den überregionalen Kontext, die automatisierte Modellgenerierung und mögliche Kommunikationskonzepte zur Aussteuerung von überregionalen Netzgebieten und Anlagenverbänden gelegt. Unter anderem wurde die Bibliothek um die Möglichkeit der Abbildung von Ladeinfrastrukturen für Elektromobilität ergänzt, um so einen weiteren Sektor in den Betrachtungsraum der Bibliothek aufzunehmen.

Die im Projekt IntegraNet durchgeführte übergeordnete regionale Analyse zeigte zudem, dass eine vergleichende Bewertung von Sektorenkopplungstechnologien durch die Vielzahl der Kontexte, in denen ein Einsatz von Sektorenkopplung möglich ist, bisher nicht möglich ist. Daher wurden in IntegraNet II die Möglichkeiten der Bewertung der verschiedenen Einsatzzwecke von Sektorkopplungstechnologien untersucht.

Ein weiterer Schwerpunkt liegt auf der Darstellung der Interaktion zwischen verschiedenen benachbarten Regionen mit sehr unterschiedlichen Versorgungsaufgaben, die bisher als autarke Gebiete betrachtet wurden. Diese Regionen stehen nun in Wechselwirkung miteinander, wobei die Modellgenerierung automatisiert auf GIS- und Szenarien-Metadaten zugreift. Die Untersuchung fokussierte sich dabei auf die Nutzung von Power-to-Heat und Power-to-Gas Anlagenverbänden im regionalen Ausgleich benachbarter Versorgungsgebiete. Um eine möglichst belastbare

Übertragbarkeit gewährleisten zu können, wurde eine deutschlandweite Kategorisierung basierend auf den urbanen Siedlungs- und Bedarfsstrukturen und den existierenden und potenziellen EE-Erzeugungskapazitäten erstellt. Hierbei wurde auf Methoden aus dem Bereich des Machine Learnings zurückgegriffen, um mittels eines eigens trainierten neuronalen Netzes eine vollautomatisierte Kategorisierung der verschiedenen Bedarfs- und Erzeugungsaspekte zu ermöglichen. Um auch das reale Stromnetz in der Analyse einzubeziehen, wurde geprüft, inwieweit die Übertragungs- und Verteilnetze bzw. die einzelnen Netzgruppen mit den gewählten Zellenstrukturen übereinstimmen. Anschließend wurde ein Modell abgeleitet, das die Netzstrukturen mit den Zellen verknüpft und somit Untersuchungen des zellulären Ansatzes unter Berücksichtigung der elektrischen Netzinfrastruktur ermöglicht.

Darüber hinaus wurde die kontinuierliche Pflege der TransiEnt-Library fortgesetzt, um einen vollständigen Baukasten für andere Anwender bereitzustellen. Im Verlauf des Projektes wurden ebenfalls das TransiEnt-Konsortium ins Leben gerufen, welches die Pflege, Weiterentwicklung und opensource Bereitstellung ermöglichen soll. Die TransiEnt Library zählt somit zu den wenigen offen verfügbaren Frameworks, die es ermöglichen, domänenübergreifende, gekoppelte Energiesysteme mit einem flexiblen Modellierungsansatz in unterschiedlichen Detaillierungsgraden zu modellieren und das instationäre Verhalten dieser Systeme präzise abzubilden.

2 Modellbibliothek TransiEnt

Im Vorgängerprojekt IntegraNet wurden Modelle der Modelica-Bibliothek TransiEnt weiterentwickelt und in der Modelica-Bibliothek IntegraNet, als Erweiterungsbibliothek für die TransiEnt-Bibliothek, bereitgestellt. Ziel war es, die Modelle der TransiEnt-Bibliothek, die für die Abbildung von größeren räumlichen Zusammenhängen auf höheren Netzebenen entwickelt wurden, um Modelle für die Abbildung von Siedlungsstrukturen und dezentralen Versorgungslösungen zu ergänzen. Um eine möglichst präzise und rechenbare Abbildung urbaner Strukturen auf Verteil- und Ortsnetzebene zu ermöglichen, wurden zum einen neue Modelle zur Abbildung dezentraler Versorgungstechnologien geschaffen, zum anderen bestehende Modelle der TransiEnt-Bibliothek im Hinblick auf Rechenzeiten im Detailgrad angepasst. Netzseitig wurden Modelle zur detaillierten Abbildung der Netzinfrastrukturen entwickelt, im Besonderen sei hier auf die neuentwickelten Fernwärme-Modelle verwiesen. Ebenso wurde das Modell *GridConstructor* als ein Strukturmodell zur einfachen Erstellung und Parametrisierung von komplexen Quartiersmodellen geschaffen.

IntegraNet II nimmt den Grundgedanken der operativen Energiesystemanalyse aus dem Vorgängerprojekt auf und widmet sich der komplexen Interaktion der Sektoren im regionalen und überregionalen Kontext. Die Simulation von Energiesystemen in Modelica ist ein wichtiger Bestandteil von IntegraNet II, ebenso wie die Weiterentwicklung der Modellbibliothek. Im Laufe von IntegraNet II konnten zudem die Modelle aus der IntegraNet-Bibliothek in die TransiEnt-Bibliothek integriert werden. Weiterhin wurde das TransiEnt-Konsortium gegründet, welches die TransiEnt-Bibliothek gemeinsam weiterentwickelt, pflegt und verbreitet. Im folgenden Kapitel wird der aktuelle Stand der TransiEnt-Struktur vorgestellt und anschließend ein Überblick über deren Weiterentwicklung gegeben.

2.1 Überblick über die Modellbibliothek TransiEnt

Das Ziel der TransiEnt-Bibliothek ist es, Modelle für die Simulation und Analyse integraler Energiesysteme und ihres dynamischen Verhaltens sowie der auftretenden Wechselwirkungen bereitzustellen. Die Bibliothek stellt dabei Modelle für Komponenten von Gas-, Wärme- und Stromsystemen (Erzeuger, Speicher, Infrastrukturen, Verbraucher) sowie verschiedene einfache Systemmodelle bereit. Einige grundlegende Modelle, insbesondere im Bereich der Wärme- und

Gasmodelle sowie grundlegende Modellierungsprinzipien wurden aus der ClaRa-Bibliothek übernommen. Diese frei verfügbare Modellbibliothek wurde von TLK und XRG Simulation entwickelt und enthält Modelle für Kraftwerkskomponenten, um kraftwerkstechnische Anlagen zu simulieren [1]. Informationen zu den grundlegenden Modellierungsprinzipien der TransiEnt-Bibliothek können unter anderem in den folgenden Publikationen gefunden werden: [2]–[5].

In der aktuellen Version besteht die TransiEnt-Bibliothek aus acht Packages. Die Package-Struktur ist in Abbildung 2-1 dargestellt.

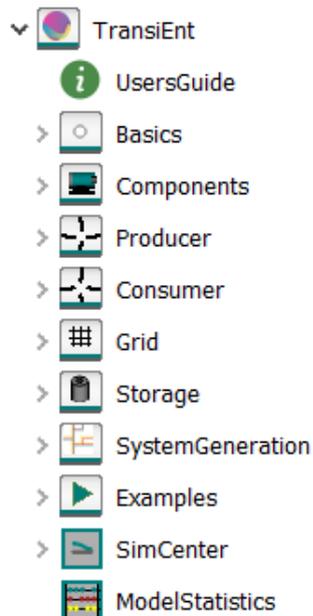


Abbildung 2-1: Package-Struktur der TransiEnt-Bibliothek

Im Basics-Package sind grundlegende Modelle wie Adapter, Regler, Funktionen, Connectoren, Datentabellen, Typen, Medienmodelle und Einheiten enthalten, die in den komplexeren Modellen der übrigen Packages Verwendung finden.

Das Components-Package enthält verschiedene Komponenten aus Gas-, Wärme und Stromsystemen. Dementsprechend wird eine Unterteilung der Modelle in die genannten drei Sektoren vorgenommen, welche sich auch in den weiteren Packages wiederfinden. Zu den Modellen innerhalb des Packages gehören unter anderem Quellen- und Senkenmodelle, Sensoren, Netzelemente (Kabel, Rohrleitungen, Ventile) el. Bauteile, Wärmeübertrager und Kompressoren.

Im Package ‚Producer‘ finden sich Erzeugermodelle zur Erzeugung von Strom (Kraftwerke, EE-Anlagen), Wärme (Wärmepumpen, Elektrokessel, Gaskessel, Solarthermie und Wärmeübergabestation) und Gas (Elektrolyseur, Methanisierung), sowie zur kombinierten Erzeugung von Wärme und Strom (KWK-Systeme).

Das Package ‚Consumer‘ ist ebenfalls nach den Verbrauchssektoren Strom, Gas und Wärme unterteilt. Die Verbrauchermodele basieren in der Regel auf einfachen mathematischen Funktionen oder tabellenbasierten Profilen. Zusätzlich sind übergeordnete und Modelle für den kombinierten Verbrauch im Subpackage ‚Systems‘ enthalten. Diese umfassen Haushaltensystems basierend auf verschiedenen Technologien (Package Systems/HouseholdEnergyConverter, vgl. Abschlussbericht IntegraNet [6]) sowie Modelle für einen zentral geregelten Pool an Wärmepumpen, Kühlschränken oder PV-Batterien.

Im Grid-Package sind Komponenten zur Regelung von Wärme-, Strom- und Gasnetzen enthalten. Das Subpackage ‚Gas‘ enthält darüber hinaus die Modelle des StaticCycles zur einfacheren Initiierung von

Modellen mit Gasnetzen. Das Package ‚Storage‘ enthält elektrische, thermische und Gas-Speichermodelle.

Im Package ‚SystemGeneration‘ sind Struktur-Modelle zur vereinfachten Erstellung und Parametrierung von Energiesystemen auf Quartiersebene (*GridConstructor*) und regionaler Ebene (Superstructure) enthalten. Der *GridConstructor* wurde im Projekt IntegraNet entwickelt ([5], [6]).

Im Package ‚Examples‘ sind einige Beispiele für die Modellierung von Regionen (‚Examples/Hamburg‘), Straßenzügen mit dem *GridConstructor* (‚GridTypology_Cologne‘) sowie von kleineren Gas-, Wärme- und elektrischen Netzen enthalten.

Für die meisten Komponentenmodelle sind unterschiedliche Detaillierungsgrade enthalten. Um die Anwendung der Modelle zu verdeutlichen, gibt es zu den Modellen, für die dies relevant ist, Testmodelle, die innerhalb der einzelnen Packages im Package ‚Check‘ zu finden sind. Hierbei sind die Modelle in der Regel in einfache Kontexte eingebunden.

2.2 Weiterentwicklung der TransiEnt-Bibliothek

Die TransiEnt-Bibliothek ist seit 2017 zum Download verfügbar und wurde seitdem in verschiedenen Forschungsprojekten angewandt und weiterentwickelt. Eine Übersicht über die beteiligten Partner und die Forschungsprojekte, in denen die TransiEnt-Bibliothek entwickelt bzw. weiterentwickelt wurde sowie die im Laufe der Zeit erfolgten Releases ist in Abbildung 2-2 dargestellt.

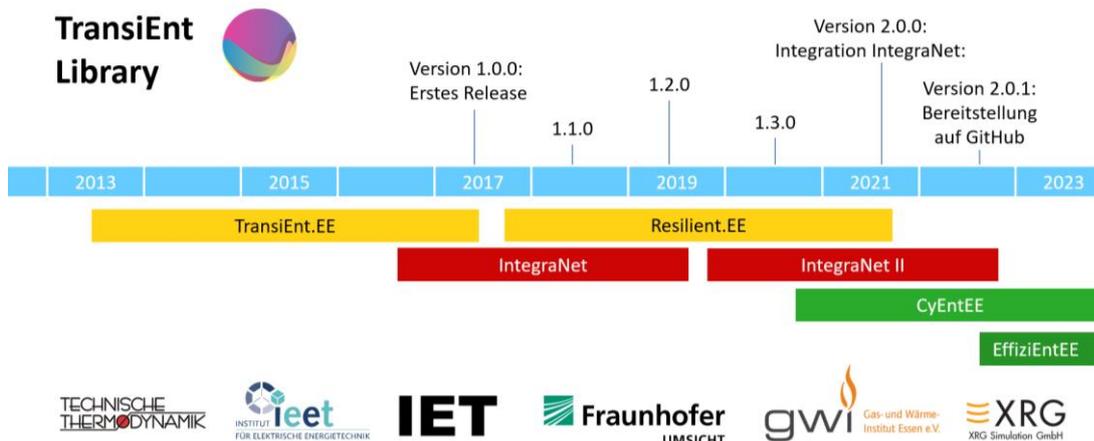


Abbildung 2-2: Übersicht über die Historie der TransiEnt-Bibliothek

Initial wurde die TransiEnt-Bibliothek durch das Institut für Technische Thermodynamik, das Institut für Elektrische Energietechnik sowie das Institut für Energietechnik der TU Hamburg (TUHH) im Rahmen des Forschungsprojekts TransiEntEE entwickelt. Das erste Release erfolgte zum Projektende im April 2017. Im Projekt IntegraNet wurden die Modelle der TransiEnt-Bibliothek für die simulativen Fragestellungen im Projekt verwendet und darauf aufbauend weitere Komponenten entwickelt, bzw. bestehende Komponenten abgewandelt. Diese wurden zunächst in der Modellbibliothek IntegraNet zusammengefasst.

Während der Projektlaufzeit von Integranet II wurde die bis dahin getrennt vorliegende Modellbibliothek IntegraNet (vgl. Abschlussbericht IntegraNet [6]) in die TransiEnt-Bibliothek integriert und mit dem Release der Version 2.0.0 im September 2021 veröffentlicht. Damit wurde der bisherige Fokus der TransiEnt-Bibliothek, der auf der Abbildung von Energiesystemen auf Transportnetzebene lag, um die Abbildung von Quartiers- und Siedlungsenergiesystemen und den zugrunde liegenden Verteil- und Ortsnetzstrukturen ergänzt.

Die Struktur der TransiEnt-Bibliothek auf der obersten Ebene wurde dabei in großen Teilen beibehalten, bis auf das neu hinzugekommene Package ‚SystemGeneration‘. Auf den unteren Ebenen wurden jedoch substanzielle Änderungen vorgenommen durch vollständig neue Modelle oder geänderte Komponenten, bei denen IntegraNet- und TransiEnt-Modelle zusammengeführt oder neue Funktionalitäten zu bestehenden Modellen hinzugefügt wurden. Bei dieser Gelegenheit wurden auch viele Unterpackage-Strukturen überarbeitet.

Die ersten Veröffentlichungen erfolgten über die Website der TransiEnt-Bibliothek. Seit dem Release der Version 2.0.1 im April 2022 ist die TransiEnt-Bibliothek nun auch über GitHub verfügbar (<https://github.com/TransiEnt-official/transient-lib>), um eine größere Transparenz hinsichtlich aktueller Entwicklungen zu ermöglichen. Darüber hinaus soll auf diesem Wege ein breiterer Nutzerkreis erreicht werden. GitHub ermöglicht auch einen direkten Austausch mit den Nutzern, welches die gerichtete Kommunikation erleichtert und eine effektive Feedback-Einbindung ermöglicht. Dabei ist es möglich über GitHub-Issues direkt Fragen an die Entwickler zu stellen, Probleme und neue Ideen einzubringen oder auch eigene Features pushen zu können.

Die Integration der IntegraNet-Modelle in die TransiEnt-Bibliothek wurde möglich durch die Gründung des TransiEnt-Konsortiums. Dieses wurde durch die Projektpartner des Projekts IntegraNet II maßgeblich vorangetrieben, um eine gemeinsame Pflege und Verbreitung sowie einen gemeinsamen Auftritt der Partner, die auch zukünftig an der Weiterentwicklung der TransiEnt-Bibliothek maßgeblich beteiligt sind, zu ermöglichen. Aktuell besteht das TransiEnt-Konsortium aus der TUHH mit ihren drei Instituten ITT, IET und ieet, Fraunhofer UMSICHT, dem Gas- und Wärme-Institut Essen sowie XRG Simulation GmbH. In regelmäßigen Treffen werden aktuelle Entwicklungen diskutiert und die Weiterentwicklung der TransiEnt-Bibliothek geplant. Das Release der gemeinsamen Transient-Version 2.0.0 sowie die Bereitstellung der Bibliothek auf GitHub gehörten zu den ersten Aktivitäten des TransiEnt-Konsortiums. Aktuelle Projekte bestehen neben dem Beheben von kleineren, in der Bearbeitung aufgefallenen Fehlern, in einer Überarbeitung der Modelldokumentation und einem Neuaufsetzen der Website.

Während der Projektlaufzeit von IntegraNet II wurden durch die IntegraNet II-Partner zwei Workshops organisiert, in denen sowohl Ergebnisse aus den Projekten vorgestellt, als auch ein Anwendungsworkshop mit Live-Demonstration durchgeführt wurden. Beide Workshops waren gut besucht und das positive Feedback sowie die vielen Rückmeldungen, auch im Nachgang zum Workshop, zeigen das hohe Interesse auch über den Kern-Anwenderkreis hinaus.

Neben der gemeinsamen Planung und Verbesserung der Bibliothek im Rahmen der gemeinsamen Arbeit im Konsortium und zahlreichen kleineren Verbesserungen und Bugfixes an verschiedenen Modellen wurden während der Projektlaufzeit von IntegraNet II insbesondere die folgenden Neuentwicklungen an der Bibliothek vorgenommen.

- Erstellung eines Modells für ein Elektrofahrzeug zur Abbildung von Quartierssystemen mit einer Kopplung des Strom- und Verkehrssektors (siehe Kapitel 3.2).
- Überarbeitung der Wärmenetzmodelle zur Reduzierung der Rechenzeit
- *GridConstructor*: Integration neuer Modelle und der Möglichkeit zur externen Ansteuerung von Komponenten (siehe Kapitel 3.3.2 und 5.2)

3 Elektromobilität im Verteilnetz

Die Berücksichtigung von Elektrofahrzeugen wird in der Verteilnetzanalyse und -planung immer wichtiger, da die zunehmende Verbreitung der Elektrofahrzeuge die Energieverbrauchsstrukturen erheblich verändern werden. Allein von 2016 bis 2020 hat sich die Anzahl der Neuzulassungen von

etwa 11.400 auf über 190.000 mehr als versechzehnfacht [7]. In den Langfristszenarien, welche im Auftrag vom BMWK erstellt wurden, werden für das Jahr 2050 je nach Szenario 12 bis 31 Mio. rein elektrische Fahrzeuge in Deutschland prognostiziert [8]. Eine von Exxon erstellte Prognose rechnet bis 2040 damit, dass 20 % aller in Deutschland zugelassenen Fahrzeuge rein elektrisch sind [9]. Die Boston Consulting Group geht in „Klimapfade 2.0“ davon aus, dass bereits 2030 14 Mio. Elektrofahrzeuge (ca. 30 %) auf deutschen Straßen fahren müssen, um das Ziel der Klimaneutralität 2045 zu erreichen [10].

Um diese neue Belastung der Verteilnetze frühestmöglich mit in die Planung und Analyse einbeziehen zu können, müssen neben dem höheren Gesamtverbrauch auch die höheren Spitzenlasten sowie veränderte Lastprofil-Formen berücksichtigt werden. Um die Komplexität der Thematik abbilden zu können, wurden im Rahmen dieses Projekts Methoden und Modelle erarbeitet, die den Verbrauch von Elektrofahrzeugen auf Verteilnetzebene in die Energiesystemplanung, -analyse und -optimierung einbeziehen.

Abschließend wurde die Anwendbarkeit der Modelle und Datensätze in einer Verteilnetzsimulation demonstriert. Dabei wurde untersucht, welchen Beitrag die netzorientierte Betriebsweise von Ladestationen zur Stabilität von schwachen Niederspannungsnetzen leisten kann.

3.1 Lastprofile für Elektrofahrzeuge

Zur Abbildung von Verbrauchern in einem Energiesystem werden üblicherweise Lastgänge eingesetzt. Diese müssen bestmöglich die Realität abbilden, denn mit der Qualität der Eingangsdaten steht bzw. fällt die Ergebnisqualität. Lastprofile für die Elektromobilität können auf unterschiedliche Weise erzeugt werden. Im Rahmen des Projekts wurden verschiedene Möglichkeiten in Betracht gezogen.

Die erste und einfachere Variante, Elektrofahrzeuge zu modellieren, ist die Abbildung von gesamten Flotten mittels eines Durchschnittlastgangs. Zu dieser Variante gibt es bereits diverse nutzbare Lastgang-Daten, die in Abhängigkeit von Haushaltstypen, Regionen, Typtagen und Ladestrategien ausgewählt werden können [11]–[13]. Diese Variante ist für die Betrachtung von Sektorenkopplungspotenzialen und einer genaueren Betrachtung für beispielsweise Lastverschiebungspotenzialen in einzelnen Haushalten jedoch sehr begrenzt einsetzbar.

Gewählt wurde daher die zweite und aufwendigere Möglichkeit, um die Elektromobilität im Verteilnetz abzubilden, indem Einzelfahrzeuge modelliert wurden. Da im Rahmen der Vorrecherchen das Nutzerverhalten als wichtigster Parameter für die Lastprofile identifiziert wurde, wurden die einzelnen Profile mithilfe des *LoadProfileGenerators* [14] generiert, welcher auf Verhaltenssimulationen von Haushalten beruht. Um mehrere Elektrofahrzeuge innerhalb eines Quartiers abzubilden, braucht jeder Haushalt plausible und einzigartige Fahr- und Parkprofile. Im Rahmen dieses Projekts wurde daher im ersten Schritt eine Datenbank simulativ erstellt und im Anschluss validiert sowie dokumentiert.

3.1.1 Zielstellung der Lastprofildatenbank

Ziel bei der Datenbank-Erstellung war es zunächst, möglichst realistische Daten zu erzeugen, die flexibel und skalierbar eingesetzt werden können. Das heißt, es sollten nicht nur Ladelastgänge generiert werden, sondern primär die Nutzung des Elektroautos in den zahlreichen und diversen Haushalten in Form von Fahrprofilen in der Datenbank abgebildet werden. Auf diese Weise können verschiedene Laderegeln implementiert und auf ihre Effektivität getestet werden.

Da für die Analyse von Sektorenkopplungspotenzialen und Regelstrategien im Verteilnetz ein konsistentes Gesamtbild essenziell ist, sollten auch die anderen relevanten Lastprofile (Wasserverbrauch und Elektrizitätsverbrauch) passend zu den simulierten Haushalten simuliert

werden. Das Ergebnis ist eine vielseitig einsetzbare Datenbank mit untereinander abgestimmten Haushaltsprofilen.

Das für die Simulation eingesetzte Tool ist der LoadProfileGenerator (LPG) [14]. Dieser zeichnet sich dadurch aus, dass die primäre Simulation eine bedürfnisabhängige Verhaltenssimulation der Haushaltsbewohner ist. Der tatsächliche Energieverbrauch wird in einem zweiten Schritt aus dem Verhalten der Bewohner*innen bestimmt. Weiterhin werden auch verhaltensunabhängige Lasten wie Kühlschränke oder Umwälzpumpen abgebildet. Der verhaltensbasierte Simulationsansatz ist besonders für die Einbeziehung von Elektroautos geeignet, da der Energie- und Wasserverbrauch stark von der Anwesenheit der Bewohner abhängt. Das ist für die Analyse intelligenter Laderegeln mit Anwesenheitsberücksichtigung, Eigenstromnutzungsoptimierung oder Vehicle-to-Grid- bzw. Vehicle-to-Building-Ansätzen besonders wichtig.

3.1.2 Lastprofilerstellung

Durch die hohe Komplexität des LPG musste die Simulation iterativ erfolgen. Die Haushaltslastgänge wurden in jeder Iteration simuliert, validiert und im Anschluss die Haushalte neu parametrisiert. Insgesamt wurden für das Jahr 2018 520 Kombinationen simuliert, von denen 518 als Profilset in einer Datenbank abgelegt wurden.

Da der LPG das Verhalten von Personen simuliert, stehen die Personen und die Haushalte im Mittelpunkt der Parametrisierung. Die Personen und Haushalte wurden weitestgehend aus der schon im LPG integrierten Datenbank übernommen. Aus 65 verschiedenen Personen und 65 verschiedenen Typhaushalten wurden insgesamt 520 Haushaltsprofile erzeugt - 8 unterschiedlich parametrisierte Haushalte pro Typhaushalt. Weiterhin wurden die Living-Patterns der Personen in den Haushalten randomisiert, sodass sich in Summe ein typischer Lastgang ergibt und es zu keinen unnatürlichen Verbrauchspeaks kommt. Weiterhin wurden auch die im Haushalt zur Verfügung stehenden Geräte durch den LPG randomisiert, sodass die Verwendbarkeit der Profile nicht durch gerätespezifische Regelmäßigkeiten eingeschränkt wird.

Um ein stimmiges Gesamtbild für die Elektromobilität zu erhalten, wurden den Haushalten Pendeldistanzen zugeordnet, die bestmöglich der realen Verteilung [15] entsprechen. Da neben den reinen Fahr- und Parkprofilen auch die elektrische Leistung der Ladevorgänge simuliert wurde, wurden die Ladesäulennennleistungen zwischen 3,7 kW und 22 kW variiert. Um die Ergebnisse trotz Randomisierung reproduzierbar zu machen, wurde bei jeder der 520 Simulationen ein einzigartiger Random-Seed verwendet und dokumentiert. Wie die Haushaltsgrößen und -typen sowie die elektromobilitätsrelevanten Parameter auf die Simulationen verteilt wurden, ist in Abbildung 3-1 dargestellt.

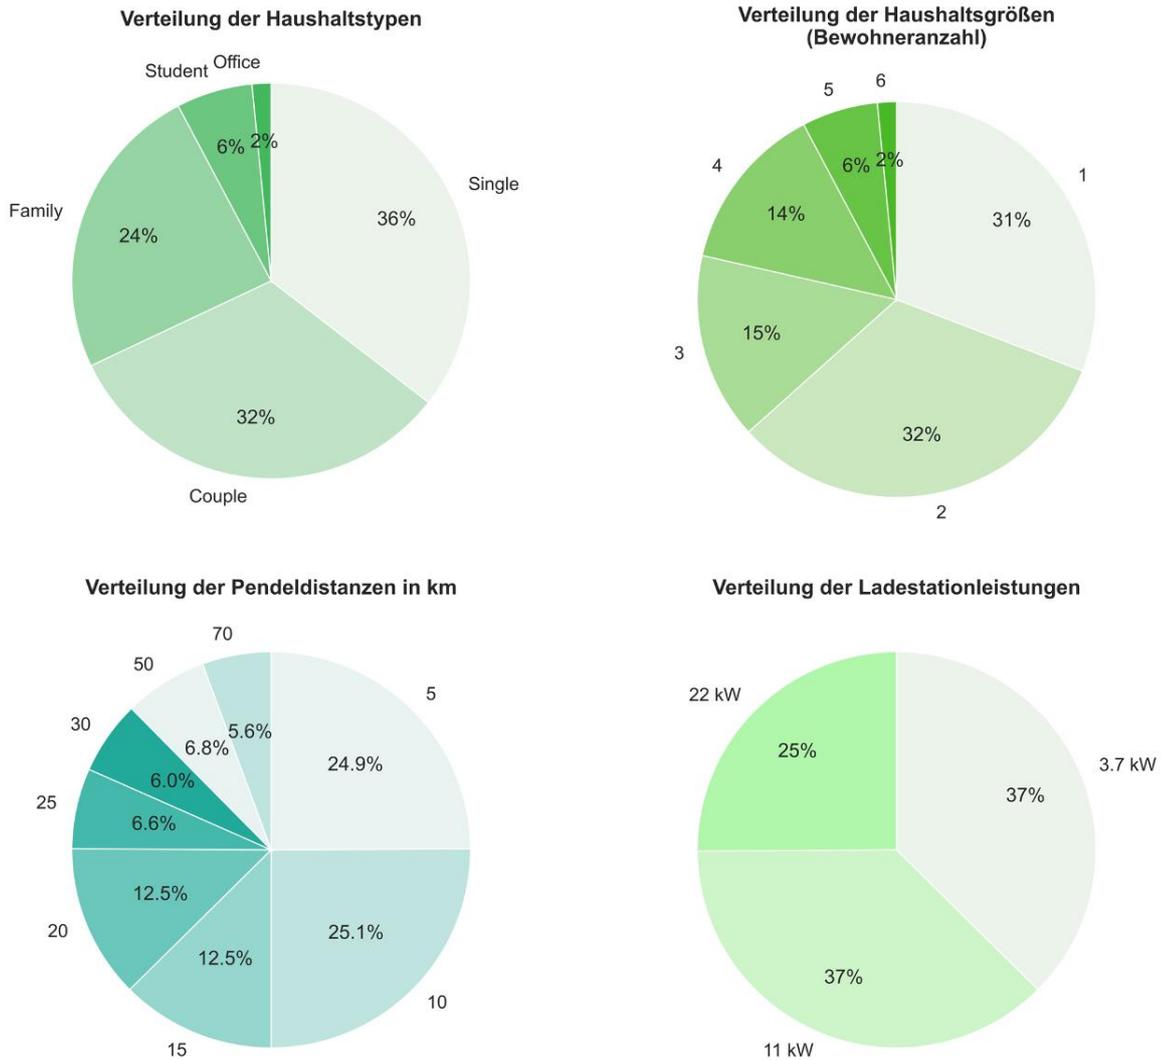


Abbildung 3-1: Informationen über die Zusammensetzung der Lastprofildatenbank. Verteilung der Haushaltstypen, Haushaltsgrößen, Pendeldistanzen und Ladestation-Nennleistungen.

Innerhalb der Datenbank ist für jeden Haushaltstyp eine einzelne Tabelle abgelegt. Die Elektromobilitätsprofile werden dabei über die vier Spalten *Location*, *State*, *Distance* und *SOC* charakterisiert. Die Integer-Werte in den Spalten *Location* und *State* repräsentieren spezifische String-Werte, die aufgrund von Speicherplatzoptimierung ersetzt wurden (vgl. Tabelle 3-1).

Tabelle 3-1: Bedeutung der Spaltenwerte in „Location“ und „State“

Integer in <i>Location</i>	Beschreibung	Integer in <i>State</i>	Beschreibung
0	Driving	0	Driving
1	Home	1	ParkingAndFullyCharged
2	Shopping	2	ParkingAndNoChargingAvailableHere
3	Event Location	3	ParkingAndCharging
4	School		
5	Workplace		

Für die universelle Einsetzbarkeit der Datenbank ist eine standardisierte Formatierung von zentraler Bedeutung. Im Postprocessing wurden die vom LPG generierten Rohdaten aus den Ergebnisordnern ausgelesen und in einem effizienten Format in CSV-Dateien gespeichert; für jeden Haushalt wird genau eine Datei in der Datenbank abgelegt. Die Tabelle hat neun Spalten, eine Spalte für die Zeit, und acht Spalten für die verschiedenen Profile. Die Spalten *Location*, *State*, *Distance* und *SOC* beziehen sich auf das Elektroauto. Die Spalten *Location* und *State* enthalten die in Tabelle 3-1 angegebenen Informationen zum zum jeweiligen Zeitstempel gehörigen Ort des Elektrofahrzeugs sowie dem Fahr- und Ladezustand.

Da je nach Anwendung unterschiedliche Zeitschritte sinnvoll sind, wurden von allen Profilen drei Versionen mit unterschiedlich großen Zeitschritten (1-, 5-, 15-minütig) erzeugt.

3.1.3 Validierung

Da die Validierung von so großen Datensätzen sehr aufwendig ist und unmöglich händisch erfolgen kann, wurden zur Validierung verschiedene Kriterien und Analyseskripte entwickelt und eingesetzt.

Analyse Elektrizitätsprofile

Zur Validierung der Elektrizitätsprofile wurden die Jahresverbrauchssummen ermittelt und mit den vom Statistischen Bundesamt erhobenen Elektrizitätsverbrauchswerten (ohne Heizanwendungen) verglichen, wobei die Haushalte getrennt nach der Haushaltsgröße betrachtet wurden. In Abbildung 3-2 sind die Verteilungen der Jahresverbräuche sowie die vom Statistischen Bundesamt für 2019 erhobenen Mittelwerte [16]. In der Abbildung fällt die Abweichung bei „3+-Personen-HH“ auf: Bei größeren Haushalten werden in der Datenbank die Verbräuche etwas unterschätzt.

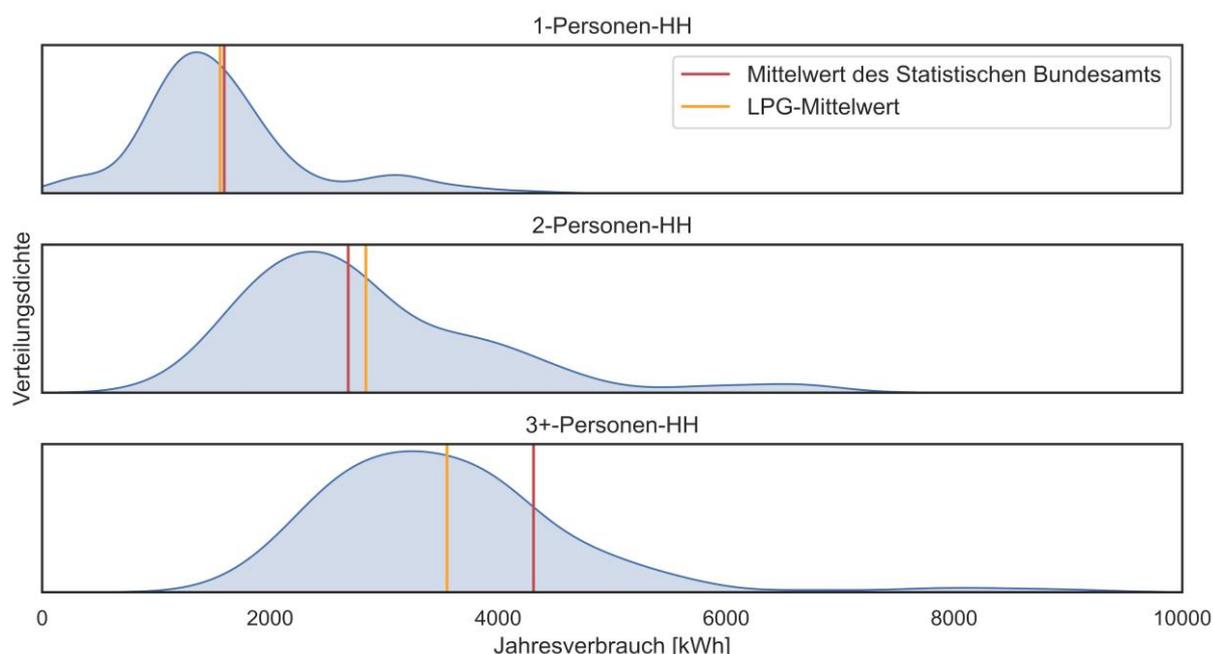


Abbildung 3-2: Vergleich der durchschnittlichen Jahresstromverbräuche der Haushaltsprofile mit Literaturdaten

Ein weiterer wichtiger Parameter bei der aggregierten Betrachtung von Elektrizitätslastgängen ist der Gleichzeitigkeitsfaktor. Zur Bestimmung des Gleichzeitigkeitsfaktors wird die reale Maximallast des aggregierten Summenprofils durch die Summe aller Maximallasten der einzelnen Haushalte geteilt. Je mehr Haushalte aggregiert betrachtet werden, desto geringer ist die erwartete Gleichzeitigkeit (vgl. Abbildung 3-3). Die für die Datenbank relevante Kurve (Kurve 3) nähert sich asymptotisch dem

Gleichzeitigkeitsfaktor **10 %**. Der Gleichzeitigkeitsfaktor für die 518 aggregierten Elektrizitätslastgänge aus der Datenbank ist **10,7 %** und somit sehr realistisch.

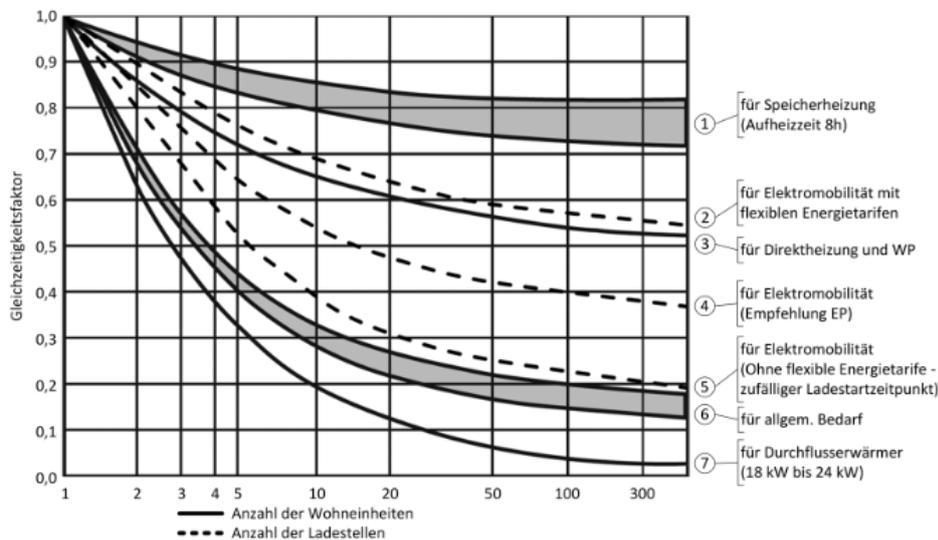


Abbildung 3-3: Gleichzeitigkeitsfaktoren in Abhängigkeit der Anzahl der Wohneinheiten [17]

Als drittes Validierungskriterium wurde die Profilform analysiert. Da die Form der Einzelprofile stark vom Verhalten der Haushaltsbewohner abhängt, kann die Profilform von Einzelhaushalten nur sehr begrenzt für eine Validierung herangezogen werden. Besser geeignet ist dagegen die Analyse des Summenprofils aller Haushalte. Hierzu wurden alle Profile aufsummiert, normalisiert und im Anschluss jeder Tag des Jahres einzeln visualisiert und mit den H0-Profilen des VDEWs, getrennt nach "Werktags" und "Wochenende", verglichen. Die normalisierten Summenprofile für die einzelnen Tage haben eine sehr ähnliche Form wie die VDEW-Profile; zwei Beispieltage sind in Abbildung 3-4 dargestellt.

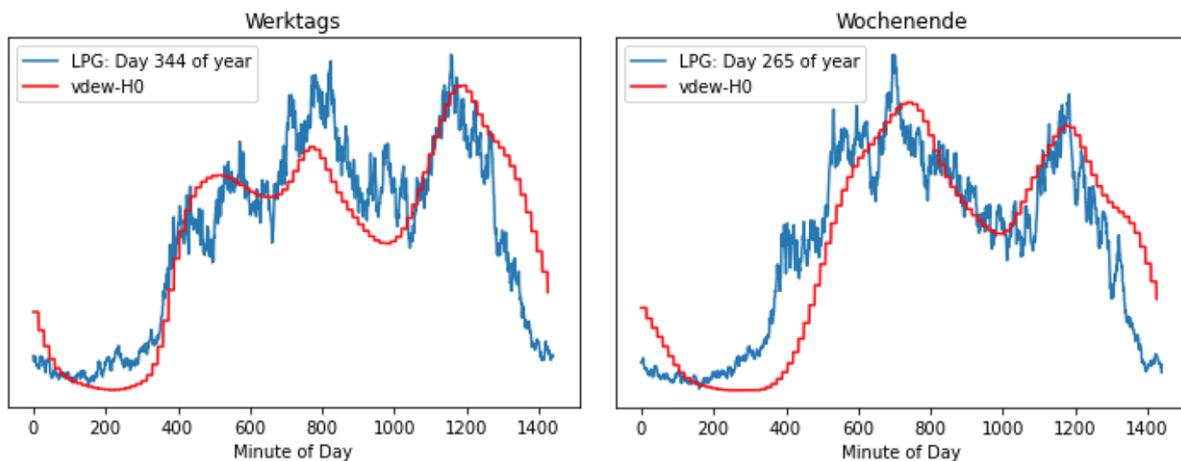


Abbildung 3-4: Zwei Beispieltage der Summenprofile in Vergleich mit den VDEW-H0-Profilen

Analyse Elektromobilitätsprofile

Die mittlere jährliche Fahrleistung beträgt laut Bundesamt für Straßenwesen pro Pkw 13727 km [18]. Die durchschnittliche Fahrleistung über die gesamte Datenbank von 518 Fahrzeugen ist 13528 km pro Pkw und Jahr und kommt somit nahezu genau auf den Vergleichswert. Auch der Visualisierung

der gefahrenen Tageskilometer für jeden Haushalt in einem Histogramm zeigt im Allgemeinen eine plausible Verteilung.

Analyse Zapfprofile

Zur Validierung der Zapfprofile wurden die Verteilung der Wasserverbräuche der einzelnen Haushalte mit dem Durchschnitt der Wasserverbräuche pro Person in Deutschland verglichen und visualisiert (vgl. Abbildung 3-5). Laut des statistischen Bundesamts wurden in Deutschland 128 Liter Wasser pro Person und Tag verbraucht [19]. Der Durchschnittswert aus der entwickelten Datenbank ist 124,4 Liter Wasser pro Person und Tag.

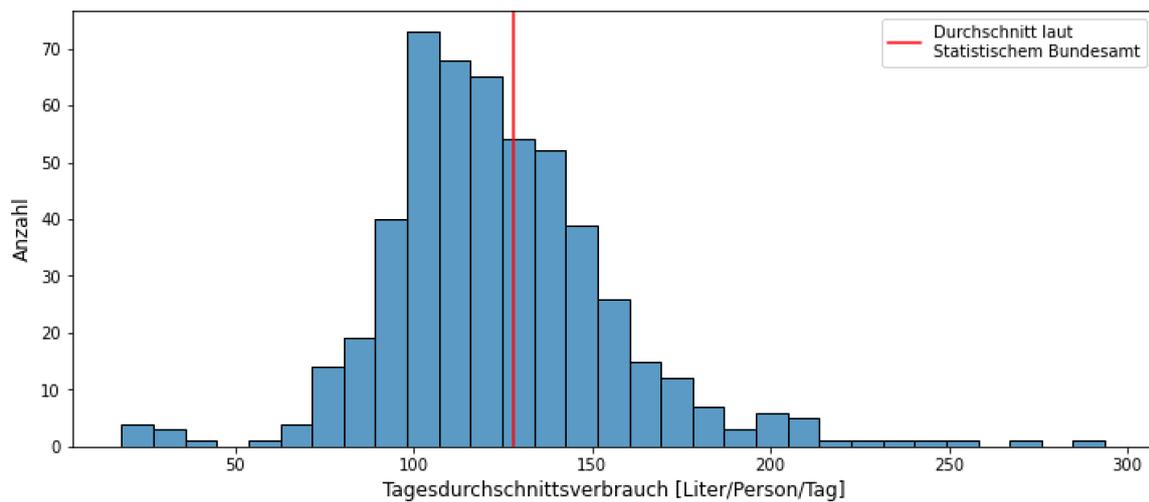


Abbildung 3-5: Verteilung der Wasserverbräuche über alle Haushalte der Datenbank

Weiterhin wurde der Wasserverbrauch getrennt für Heiß- und Kaltwasserverbrauch betrachtet. Im Durchschnitt verbraucht jede Person in der Datenbank etwa 86 Liter Kaltwasser und etwa 38,4 Liter Heißwasser pro Tag. Dies kommt sehr nahe an den allgemein angenommenen Richtwert von 40 Litern Heißwasser pro Person und Tag heran.

Zusätzlich wurden auch die Profilformen der Zapfprofile auf Plausibilität geprüft. Dazu wurde für jeden Haushalt ein Durchschnittstagesprofil gebildet und zusätzlich die maximalen Verbrauchswerte (höchste Minutenwerte) überprüft. Hierbei wurden keine Unregelmäßigkeiten festgestellt.

3.2 Modelica-Modell ElectricCar

Zur Abbildung von Elektrofahrzeugen wurde ein Modell zur Aufnahme in das Package ‚Consumer/Electrical‘ der TransiEnt-Bibliothek erstellt. Das Modell basiert auf dem bereits vorhandenen Batteriemodell der TransiEnt-Bibliothek. Als Input wird ein Fahrprofil des Elektrofahrzeuges benötigt. Dieses wird über zwei Tabellen in das Modell eingelesen, die einerseits die von dem Elektrofahrzeug pro Zeitschritt zurückgelegte Distanz (*carDistance*) und andererseits den aktuellen Standort des Fahrzeugs mittels Integerwert (*carLoc*) beschreibt (vgl. Tabelle 3-1). Diese Daten können aus der in Kapitel 3.1 beschriebenen Datenbank entnommen werden.

Als Parameter können der Stromverbrauch pro 100 km (*carEfficiency*), die Batteriekapazität sowie die Ladeleistung (*P_charge*) durch die Nutzerin oder den Nutzer spezifiziert werden.

Ein Entladen mit der Leistung $P_{driving}$ geschieht in jedem Zeitschritt, in dem im Ladeprofil eine Fahrstrecke angegeben ist:

$$P_{driving} = - \frac{carEfficiency}{100} * carDistance * \frac{60}{timeStepSize}$$

Ein Laden der Batterie über den Netzanschluss ist nur möglich, wenn das Auto zu Hause parkt ($carLoc=1$). Sobald dieser Fall eintritt, wird die Batterie mit der Ladeleistung P_{charge} aufgeladen, bis diese vollständig gefüllt ist.

Es ist ebenso möglich, dass Fahrzeug an anderen, über die $carLoc$ -Tabelle spezifizierten Orten, geladen wird (z.B. am Arbeitsplatz). In diesem Fall erfolgt eine Erhöhung des Batteriefüllstands, jedoch ohne dass dem Netzanschlusspunkt eine Leistung entnommen wird. An welchen weiteren Orten ein Aufladen des Fahrzeugs erfolgt, kann ebenso durch die Anwenderin oder den Anwender über den Parameterdialog gesetzt werden.

Zusätzlich wurde für das Elektromobilitätsmodell eine Schnittstelle für eine externe Laderegulung implementiert, mit welcher die Ladeleistung von außen begrenzt werden kann. Sowohl eine einfache Leistungsbegrenzung als auch die Lastumkehrung im Sinne von Vehicle-To-Grid kann mit dem Modell umgesetzt werden.

3.3 Use Case: Netzorientierter Betrieb in schwachen Niederspannungsnetzen

Die Zunahme von Elektrofahrzeugen in Deutschland und der damit verbundene Ausbau der Ladeinfrastruktur führen unmittelbar zu einer zusätzlichen Belastung der Verteilnetze. Hinzu kommen weitere elektrische Verbraucher wie zum Beispiel Wärmepumpen. Insbesondere in schwach ausgebauten Netzen, die bereits heute nahe an ihrer Belastungsgrenze betrieben werden, müssen Maßnahmen ergriffen werden, damit auch in Zukunft ein sicherer und zuverlässiger Netzbetrieb gewährleistet ist.

Grundsätzlich stehen den Netzbetreibern zwei unterschiedliche Lösungsansätze zur Verfügung. Zum einen lässt sich die Netzkapazität durch Netzausbau erhöhen. Das ist allerdings mit einem erheblichen monetären und zeitlichen Aufwand verbunden. Alternativ können durch eine flächendeckende Netzautomatisierung in den unteren Spannungsebenen die Netzkapazitäten besser ausgenutzt werden und somit der Netzausbau reduziert oder zumindest verzögert werden.

Im Rahmen des Projekts wurde der zweite Lösungsansatz (Netzautomatisierung) aufgegriffen und explizit auf die Ladeinfrastruktur von Elektrofahrzeugen angewandt. Es wurde modellbasiert untersucht, wie sich die netzorientierte Steuerung von Ladestationen auf den Netz- und Anlagenbetrieb auswirkt.

Zusätzlich ist in Zusammenarbeit mit dem Fraunhofer SIT eine Studie entstanden, in der die Folgen und Risiken möglicher Cyberangriffen auf solche Systeme detailliert untersucht wurden [20]. Die Studie basiert auf dem gleichen Szenario wie in diesem Projekt, sodass im Folgenden nur die wesentlichen Aspekte wiederholt werden und für Details auf die Veröffentlichung verwiesen wird.

3.3.1 Szenario

Ein erhöhtes Aufkommen von Elektrofahrzeugen innerhalb eines Niederspannungsnetzes wird zunächst vor allem in vorstädtischen Regionen erwartet. Hier befinden sich hauptsächlich Ein- und Zweifamilienhäuser (EFH, ZFH), dennoch ist die Lastdichte aufgrund der engen Bebauung verhältnismäßig hoch. Relevante Technologien sind hier neben den Ladestationen für Elektrofahrzeuge vor allem Wärmepumpen, Photovoltaikanlagen und Batteriespeicher. Auf der Basis dieser Vorüberlegungen wurde für die Untersuchung ein vorstädtisches Quartier definiert, welches in den 90er Jahren erbaut und im Laufe der Zeit teilweise modernisiert wurde. Dabei wurde die Verbrauchsstruktur bzw. die Durchdringung strombasierter Technologien wie folgt gewählt:

- 170 Wohneinheiten, verteilt auf 118 EFH und 26 ZFH, teilweise saniert
- 9 % Single-, 23 % Zweipersonen- und 68 % Familienhaushalte
- 43 PV-Anlagen mit Batteriespeichern

- 43 Wärmepumpen
- 85 Elektrofahrzeuge mit privater Ladestation (50 % Durchdringung)
- 14-21 MWh Raumwärme- und Trinkwarmwasserbedarf pro Haushalt
- 2-8 MWh Strombedarf pro Haushalt
- Transformator: 400 kVA, Kabel: 185 mm² (Aluminium)

Alle Wohneinheiten sind an dasselbe Niederspannungsnetz angeschlossen. Dazu wurde ein vorstädtisches Referenznetz aus [21] ausgewählt, welches zum Zeitpunkt der Errichtung nach typischen Planungskriterien ausgelegt wurde und somit für zukünftige Anforderungen möglicherweise zu schwach ist. Die Struktur des Netzes ist in Abbildung 3-6 dargestellt.

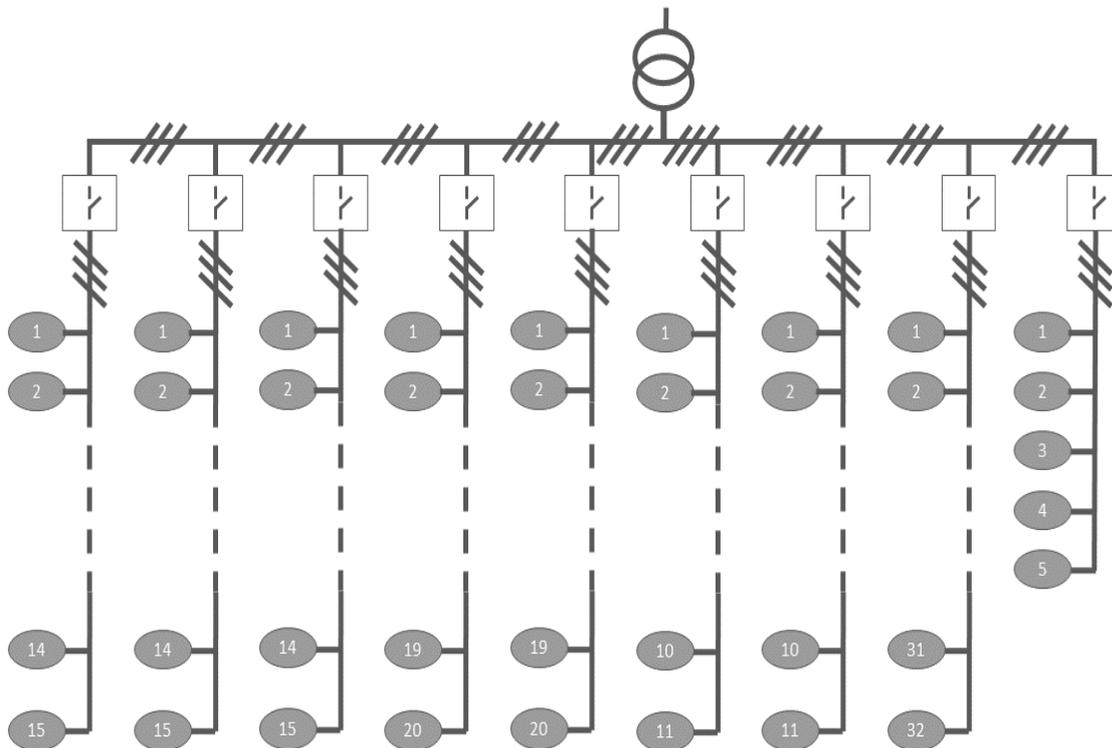


Abbildung 3-6: Struktur des betrachteten Referenznetzes aus [21]

Zur Bewertung der netzorientierten Betriebsweise von Ladestationen wurden drei Varianten simuliert:

1. Ohne Elektromobilität (Referenzfall)
2. Ungesteuerter Betrieb
3. Netzorientierter Betrieb

Die erste Variante soll zeigen, dass der Netzbetrieb ohne den Zubau von Ladestation stabil ist und keine Engpasssituationen auftreten. In der zweiten Variante werden die Ladestationen ungesteuert betrieben. Das heißt, die Batterien werden unmittelbar nach dem Anschluss an eine Ladestation geladen. Es wird dabei davon ausgegangen, dass die Fahrzeuge an eine Ladestation angeschlossen werden, sobald sie zu Hause geparkt werden. In der dritten Variante wird in Ergänzung zu Variante 2 im Falle eines kritischen Netzzustandes die maximale Ladeleistung aller Ladestationen herabgesetzt. Erst wenn der kritische Zustand vorüber ist, kann wieder mit Nennleistung geladen werden.

3.3.2 Simulation

Die Simulation wurde in Dymola mithilfe der TransiEnt-Bibliothek durchgeführt. Dazu wurde vor allem das Modell des *GridConstructors*, das im Projekt IntegraNet entwickelt wurde, eingesetzt. Das vollständige Quartiersmodell ist in Abbildung 3-7 dargestellt. Dabei sind die einzelnen Elemente des *GridConstructors* über Konnektoren der elektrischen Netzinfrastruktur miteinander verbunden. Der Netztransformator ist nicht explizit abgebildet, sondern ist Teil des idealen Netzanschlusses. Es wird lediglich der Scheinleistungsfluss aus dem übergeordneten Netz mithilfe eines Sensors erfasst und an ein Steuerungselement übergeben. Das Steuerungselement ermittelt auf der Basis der am Transformator erfassten Scheinleistung ein Steuersignal für die Ladestationen.

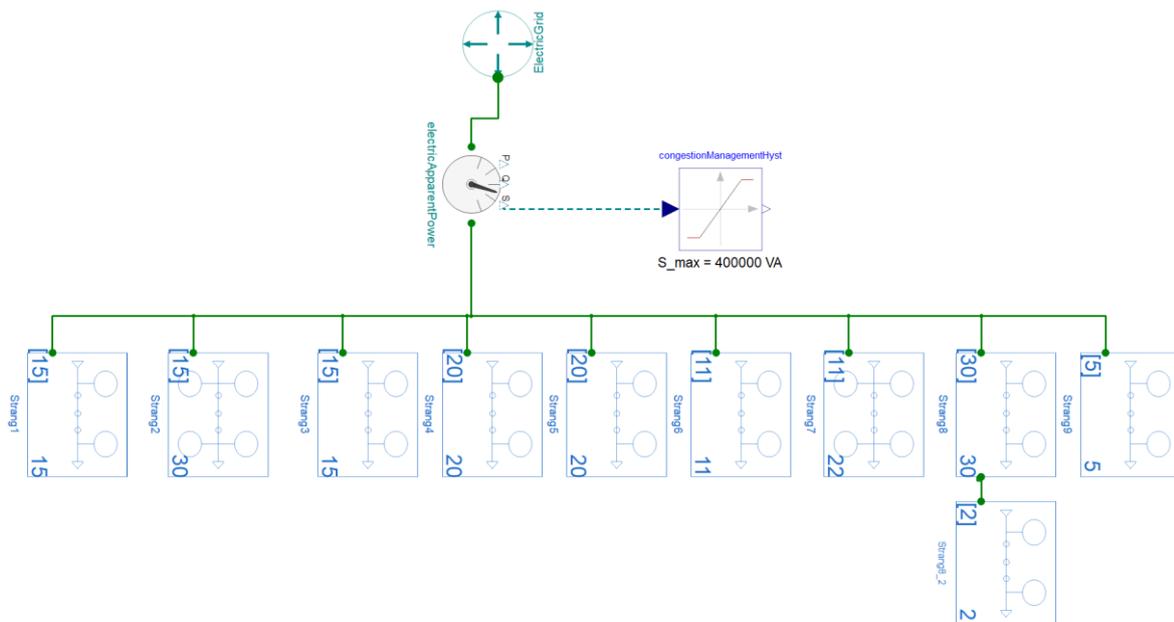


Abbildung 3-7: Screenshot des Simulationsmodells

GridConstructor

Jedes *GridConstructor*-Element bildet mehrere Gebäude inklusive der integrierten Energieanlagen in einem Array ab. Das ermöglicht eine übersichtliche und effiziente Parametrierung aller Gebäude und Anlagen. Die randomisierten Last- und Mobilitätsprofile der einzelnen Wohneinheiten stammen aus der entwickelten Lastprofildatenbank (vgl. Kapitel 3.1). Die Einspeisezeitreihen der Erzeugungsanlagen basieren auf Wetterdaten für ein Testreferenzjahr von Miesbach aus [22]. Die Parametrierung der Anlagen erfolgte ebenfalls auf der Basis dieser Wetterdaten.

Der Betrieb der Anlagen erfolgt rein bedarfsorientiert (ungesteuert). Dazu ist zum Betrieb der PV-Batteriespeicher eine einfache Logik implementiert: Im Rahmen der Kapazitätsgrenzen wird eingespeichert, wenn innerhalb eines Gebäudes die Erzeugung größer als der Verbrauch ist und ausgespeichert, wenn der Verbrauch die Erzeugung übersteigt.

Im Rahmen dieses Projekts wurde der *GridConstructor* um die Elektromobilität erweitert. Es ist damit möglich, Mobilitätsprofile und Parameter der Ladeinfrastruktur zu hinterlegen, sodass typische Ladekurven und somit der elektrische Verbrauch von Elektrofahrzeugen berücksichtigt werden können. Darüber hinaus wurde eine Schnittstelle integriert, über die ein externes Signal an die einzelnen Ladestationen der Wohngebäude übergeben werden kann. Dieses Signal enthält die maximal zulässige elektrische Leistung der Ladestation zum jeweiligen Zeitpunkt.

Netzorientierte Steuerung

Die netzorientierte Steuerung greift ein, sobald ein Netzengpass identifiziert wurde oder unmittelbar bevorsteht. Da im Rahmen des Projekts lediglich konzeptionell die Potenziale der Netzautomatisierung analysiert werden sollen, wird die Steuerung vereinfacht umgesetzt und es wird nicht der gesamte Netzzustand beim Engpassmanagement berücksichtigt. Insbesondere in vorstädtischen Niederspannungsnetzen werden Grenzwertverletzungen zunächst am Transformator erwartet, sodass hier lediglich der Leistungsfluss am Transformator berücksichtigt wird.

Dazu wird der Scheinleistungsfluss S auf der Sekundärseite des Transformators (400 V) erfasst und an das Steuerungselement übergeben. Der vollständige Regelkreis dazu ist in Abbildung 3-8 dargestellt. Auf der Basis einer Hysteresekurve wird die maximal zulässige Leistung der Ladestationen berechnet (P_{\max}). Die Hysteresekurve ist so parametrisiert, dass bereits bei 80 % der Bemessungsleistung des Transformators (320 kVA) die Reduzierung der maximalen Ausgangsleistung beginnt. Fällt die Transformatorleistung anschließend auf unter 75 %, wird die maximale Ausgangsleistung wieder erhöht. Bei unter 50 % werden alle Begrenzungen aufgehoben. Zur Stabilisierung des Systemverhaltens erfolgt die Berechnung nicht kontinuierlich, sondern wird minütlich vorgenommen und verzögert ausgegeben. Dabei wird eine maximale Änderungsrate der zulässigen Ladeleistung von $\pm 1\text{ kW/min}$ berücksichtigt. Alle Ladestationen erhalten anschließend im Sinne der Diskriminierungsfreiheit dasselbe Signal mit der maximal zulässigen Ladeleistung ($P_{\max,d}$).

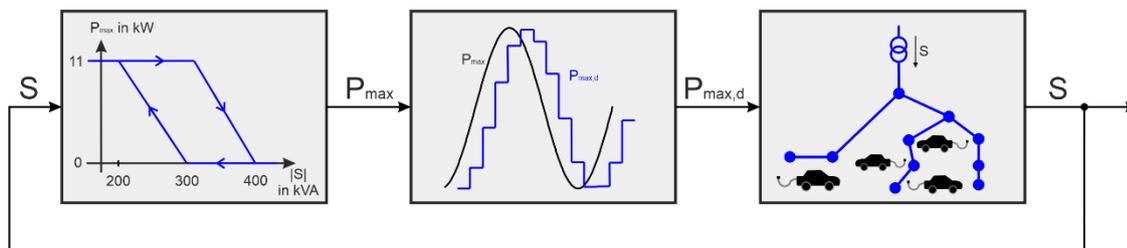


Abbildung 3-8: Regelkreis zur Umsetzung des Engpassmanagements

Es hat sich gezeigt, dass das beschriebene Steuerungsdesign für das gegebene Szenario zu einem stabilen Systemverhalten führt und Grenzwertverletzungen nicht oder nur kurzzeitig (< 3 Minuten) auftreten. Dennoch muss darauf hingewiesen werden, dass dies kein geeigneter Vorschlag für die tatsächliche Realisierung einer Steuerung zum Engpassmanagement ist. Die beschriebene Hystereseregelung ist nicht hinreichend robust und es werden mögliche Grenzwertverletzungen an den einzelnen Kabelsträngen – auch in Bezug auf die Spannung – nicht berücksichtigt. In diesem konkreten Anwendungsfall zeigten sich allerdings plausible Ergebnisse und keine weiteren Grenzwertverletzungen, sodass das gewählte Modell zur Untersuchung möglicher Potenziale des netzdienlichen Ladens geeignet ist.

3.3.3 Auswertung

Zur Bewertung der Auswirkungen einer netzorientierten Steuerung von Ladestationen wurde für die drei beschriebenen Varianten jeweils eine Jahressimulation durchgeführt. Unter Berücksichtigung der Wetterdaten von 2019 ergeben sich die in Abbildung 3-9 dargestellten Jahresdauerlinien.

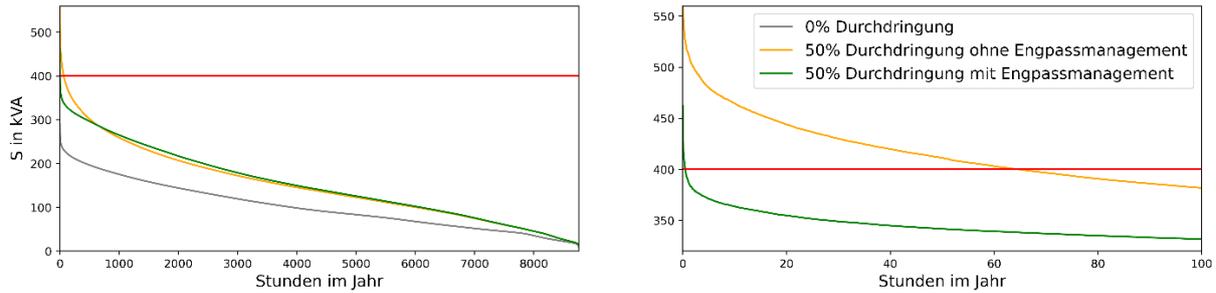


Abbildung 3-9: Scheinleistung am Transformator als Jahresdauerlinien: Darstellung aller Stunden des Jahres (links), Darstellung der 100 Stunden mit der höchsten Belastung (rechts)

Es ist zu erkennen, dass im Referenzfall ohne Elektrofahrzeuge die maximale Belastung des Transformators deutlich unter dem Grenzwert von 400 kVA liegt. Somit ist der Betrieb des Netzes in diesem Fall unkritisch. Werden in demselben Netz in 50 % der Haushalte Elektrofahrzeuge betrieben, steigt die Belastung des Transformators in weiten Teilen des Jahres erheblich an. In ca. 65 Stunden des Jahres wird die Belastungsgrenze des Transformators überschritten, sodass ein sicherer Netzbetrieb in dieser Konfiguration nicht möglich ist. Wird in derselben Konfiguration das Engpassmanagement umgesetzt, indem die Elektrofahrzeuge netzorientiert geladen werden, treten dagegen keine signifikanten Überschreitungen der Belastungsgrenze auf. Lediglich für wenige Minuten im Jahr treten Engpasssituationen auf, die allerdings unkritisch sind, da Transformatoren kurzzeitige Überschreitungen der Bemessungsleistung erlauben.

Die Funktionsweise des Engpassmanagements ist in Abbildung 3-10 für einen Wintermonat (Februar) dargestellt.

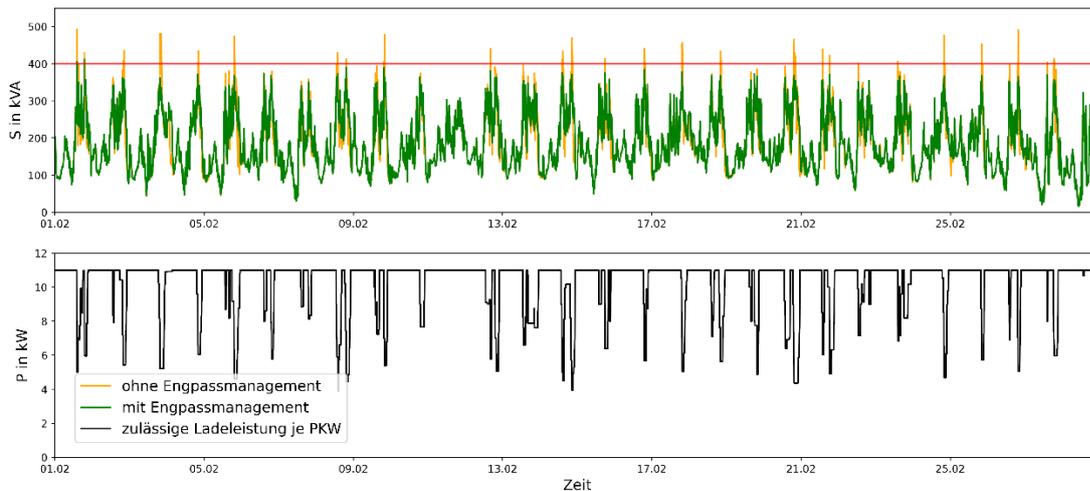


Abbildung 3-10: Engpassmanagement im Februar: Scheinleistung am Transformator (oben), zulässige Ladeleistung je PKW (unten)

Ohne Engpassmanagement käme es beinahe an jedem Tag zu einer Überschreitung der Belastungsgrenze am Transformator. Daher wird durch das Engpassmanagement fast täglich in den Betrieb der Ladestationen eingegriffen und die Ladeleistung begrenzt. Dabei treten die einzelnen Eingriffe in der Regel am späten Nachmittag oder Abend auf und dauern einige Minuten bis wenige Stunden. Es zeigt sich, dass alle Engpässe effektiv aufgelöst werden können.

Im Vergleich dazu zeigt Abbildung 3-11 die Funktionsweise des Engpassmanagements in einem Sommermonat (August).

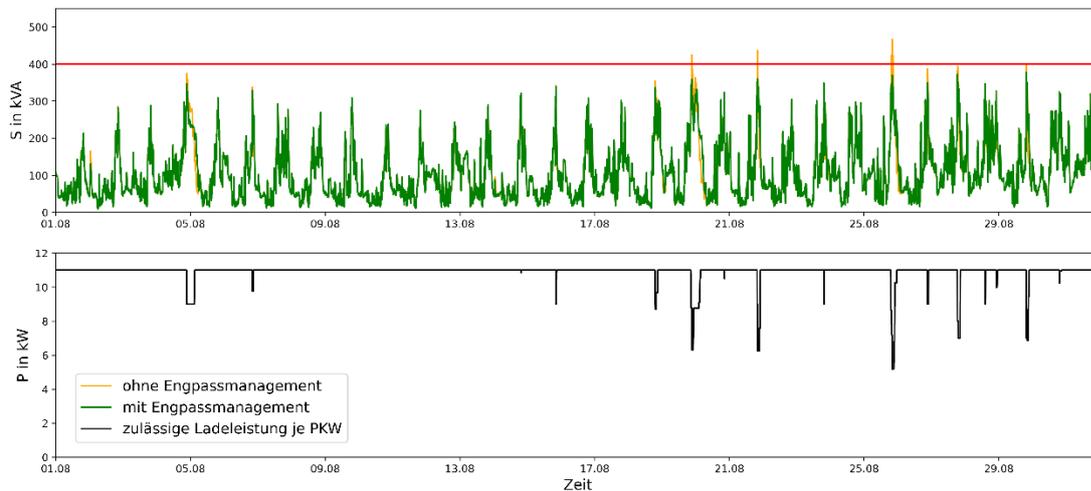


Abbildung 3-11: Engpassmanagement im August: Scheinleistung am Transformator (oben), zulässige Ladeleistung je PKW (unten)

Es ist zu erkennen, dass wesentlich seltener Engpässe auftreten und im deutlich geringeren Umfang in den Betrieb eingegriffen werden muss. Dies liegt darin begründet, dass zum einen im Sommer weniger Wärmeleistung bereitgestellt werden muss und somit elektrische Heizungen seltener bzw. mit geringerer Leistung betrieben werden und zum anderen die Einspeisung aus PV-Anlagen dazu beiträgt, den Leistungsfluss am Transformator zu reduzieren. Es fällt außerdem auf, dass gelegentlich die maximale Ladeleistung begrenzt wird, obwohl kein Engpass vorliegt bzw. erwartet wird. Die Ursache dazu findet sich in der konkreten Umsetzung der Steuerung: Das Engpassmanagement ist so realisiert, dass bereits bei einer zwar unkritischen, aber dennoch hohen Transformatorbelastung von 320 kVA mit dem Abregeln der Ladestationen begonnen wird. Für das einzelne Fahrzeug ist die Begrenzung in der Regel allerdings von geringer Dauer, sodass die Auswirkungen auf den Ladezustand der Batterie marginal sind.

Zur detaillierten Untersuchung des Verhaltens eines einzelnen Fahrzeugs zeigt Abbildung 3-12 die Ladeleistung und den Ladezustand (State of Charge – SOC) eines Fahrzeugs an einem Wintertag (Donnerstag, 14. Februar). Während mittags die Netzbelastung noch unkritisch ist und das Fahrzeug mit maximaler Leistung aufgeladen werden kann, wird die Ladeleistung am Abend für rund 2 Stunden auf ca. 6 kW begrenzt. Dadurch ist die Batterie im Vergleich zum ungesteuerten Betrieb zwar erst etwa eine Stunde später, aber dennoch rechtzeitig vor der nächsten Fahrt, vollständig aufgeladen.

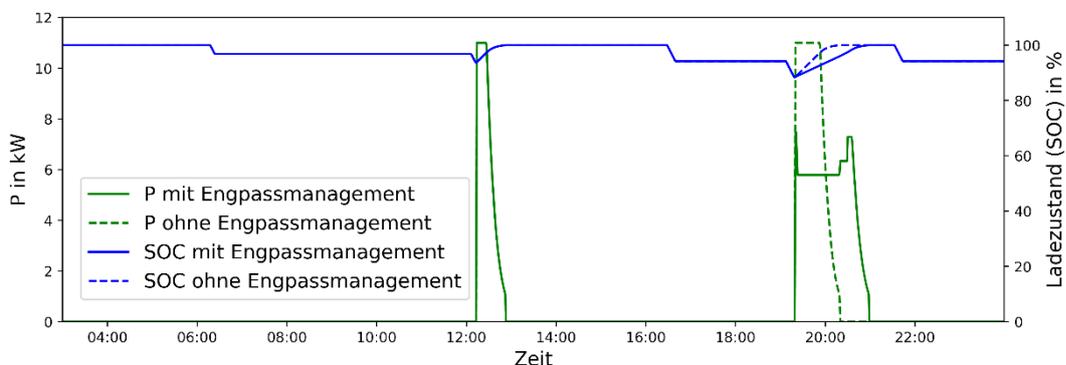


Abbildung 3-12: Ladeleistung und Ladezustand der Batterie eines ausgewählten Fahrzeugs

Die vorliegenden Ergebnisse der Untersuchung zeigen, dass die netzorientierte Steuerung von Ladestation die Integration der Elektromobilität in schwachen Netzen effektiv unterstützen kann. In dem hier betrachteten Energiesystem konnte das Netz sicher betrieben werden, wenngleich 85 von

170 Haushalten regelmäßig ein Elektrofahrzeug nutzen und laden. Die Auswirkungen auf das einzelne Fahrzeug sind dabei als gering anzusehen, da die zulässige Ladeleistung nur für kurze Zeiträume reduziert wird und das Laden nie vollständig unterbunden wird. Da die Standzeiten und somit die Möglichkeit zum Laden im Vergleich zu den Abwesenheitszeiten bzw. zum Verbrauch verhältnismäßig groß sind, hat die Anwendung des Engpassmanagements nur einen geringen Einfluss auf den Ladezustand bzw. auf die Reichweite bei Fahrtantritt.

Die Wirksamkeit des Engpassmanagements hängt dabei von der konkreten Umsetzung der Steuerung ab. Die hier gewählte Regelungsstrategie hat sich als zweckmäßig in der Hinsicht erwiesen, dass Engpässe effektiv aufgelöst werden und gleichzeitig in Situationen, in denen keine Engpässe vorliegen, lediglich geringfügig in den Betrieb eingegriffen wird. Für eine reale Anwendung müsste die vorgestellte Regelungsstrategie in Bezug auf Stabilität und Robustheit geprüft bzw. optimiert werden. Außerdem müsste das Engpassmanagement um die Betrachtung von Grenzwertverletzungen (Strom und Spannung) an den einzelnen Leitungen erweitert werden.

Zusammenfassend lässt sich festhalten, dass Elektrofahrzeuge zwar kritisch zur Belastung des elektrischen Netzes beitragen können, gleichzeitig aber auch einen zentralen Beitrag zu einem erfolgreichen Engpassmanagement leisten können.

4 Kontextbasierter Ansatz zur Potenzialbewertung

Mit dem zunehmenden Ausbau semi-disponibler Stromerzeugungsanlagen auf Basis von Wind und Sonne steigt auch der Bedarf, die Diskrepanz zwischen Stromerzeugung und -verbrauch auszugleichen. Potenziale für einen solchen Ausgleich bietet insbesondere die Sektorenkopplung mittels Power-to-X-Anlagen (PtX-Anlagen). So können beispielsweise Wärmepumpen (Power-to-Heat) in Kombination mit Wärmespeichern und der thermischen Trägheit von Gebäuden gezielt eingesetzt werden, um die Stromnachfrage von Zeiten geringer Verfügbarkeit regenerativ erzeugten Stroms zu Zeiten mit einer hohen Verfügbarkeit zu verschieben.

Inwiefern PtX-Anlagen genutzt werden können, um die Diskrepanz zwischen Stromerzeugung und -verbrauch auszugleichen, hängt von vielfältigen Faktoren ab. Zum einen wird der Ausgleichsbedarf durch die vorhandenen semi-disponiblen Erzeugungsanlagen auf der einen und die Verbraucherstruktur auf der anderen Seite vorgegeben. Zum anderen sind bei einem identischen Ausgleichsbedarf PtX-Anlagen je nach Netzstruktur und -beschaffenheit in unterschiedlich großem Umfang einsetzbar, um den Ausgleich zu leisten. Alle diese Faktoren sind räumlich (bspw. zwischen urban und rural oder auch industriell und landwirtschaftlich geprägten Regionen) stark verschieden.

Um das Ausgleichspotenzial von PtX-Anlagen deutschlandweit abzuschätzen, müssen daher die unterschiedlichen lokalen Gegebenheiten berücksichtigt werden. Diese Gegebenheiten werden im Folgenden als Kontext zusammengefasst. Ziel ist es, Regionen mit vergleichbaren Kontexten zu identifizieren. Untersuchungsergebnisse hinsichtlich des Ausgleichspotenzials einer Region mit einem spezifischen Kontext können dann auf andere Regionen mit vergleichbarem Kontext übertragen werden. Im Ergebnis erlaubt dies eine detaillierte und gleichzeitig umfassende deutschlandweite Potenzialbewertung von PtX-Anlagen.

4.1 Mögliche Aspekte eines Kontexts

Als erster Schritt sind die regionalen Bezugspunkte auszuwählen, auf die der kontextbasierte Ansatz aufbaut. Analog zu den Vorarbeiten aus Integranet wird auch in Integranet II die NUTS 3-Ebene (Landkreise und kreisfreie Städte) zu diesem Zweck herangezogen. Entsprechend werden die regionalen Gegebenheiten auf Landkreisebene analysiert.

Landkreise und kreisfreie Städte unterscheiden sich in vielerlei Hinsicht. Welche dieser Unterschiede sich auf die Potenziale von PtX-Anlagen heute und in Zukunft auswirken, ist weitestgehend unklar. Die Zahl der Aspekte, welche hinsichtlich ihres Einflusses untersucht werden können, ist jedoch aufgrund eingeschränkter Datenverfügbarkeit auf Landkreisebene begrenzt.

Eine eigenständige Datenerfassung für alle 402 NUTS 3-Regionen in Deutschland ist im Rahmen des Forschungsprojekts nicht leistbar. Entsprechend muss auf frei verfügbare Daten zurückgegriffen werden. Zu den verfügbaren Daten, die Einfluss auf die Potenziale von PtX-Anlagen haben können, zählen insbesondere:

- die Bevölkerungsanzahl,
- die Gebäude- bzw. Einfamilienhäuser-Anzahl,
- die Anzahl der PV-Anlagen und Wärmepumpen und insbesondere
- das Wetter.

Das Statistische Bundesamt bietet Daten aus dem Jahr 2020 hinsichtlich der Bevölkerungsanzahl aller Regionen an [23]. Eine Zählung der Gebäude – unter anderem aufgeteilt nach Ein- und Mehrfamilienhäusern – fand zuletzt im Jahr 2022 statt. Die Ergebnisse standen während der Projektlaufzeit jedoch noch nicht zur Verfügung, daher wurden die Ergebnisse der letzten Befragung aus 2011 verwendet. Diese sind unter www.zensus2011.de zu finden. Die Gebäudedaten wurden im Sinne der Landkreisreformen aus den Jahren 2011 und 2016 angepasst.

Die Daten der aktuellen PV-Anlagen können über das Marktstammdatenregister der Bundesnetzagentur [24] abgerufen werden. Für die vorliegende Untersuchung wurden nur diejenigen Anlagen verwendet, die eine installierte Leistung von 10 kWp nicht überschreiten und entsprechend als privat genutzte PV-Anlage einzuordnen sind. Die identifizierten Anlagen wurden entsprechend ihrer Postleitzahl den jeweiligen Regionen zugeordnet.

Marktdaten zu Wärmepumpeneinheiten sind nicht öffentlich zugänglich. Wir nehmen es daher zunächst als ausreichend an, dass die Häuser, in denen Wärmepumpen installiert sind, größtenteils mit den Häusern korrelieren, in denen eine PV-Anlage installiert ist.

Die Wetterdaten werden vom Deutschen Wetterdienst zur Verfügung gestellt [25]. Für dieses Projekt wurden Zeitreihen für jedes Stadtteilzentrum erstellt – für die Temperatur und die direkte, diffuse und globale Sonneneinstrahlung über ein Jahr.

4.2 Auswahl relevanter Merkmale

Um die Ähnlichkeit bzw. Verschiedenheit der Landkreise mittels einer Cluster-Analyse untersuchen zu können, ist die Auswahl relevanter Merkmale notwendig. Die Ähnlichkeit der Landkreise wird im Anschluss im Hinblick auf diese Merkmale untersucht. Aus den oben genannten Quellen sind folgende skalare Merkmale ableitbar und grundsätzlich relevant:

- Die Gesamtzahl der Gebäude in einem Landkreis bzw. einer kreisfreien Stadt. Diese ist für die Simulationen notwendig, da sich die Netzstruktur und die Leistung der Technologien daran orientieren.
- Die Gesamtzahl der Einfamilienhäuser, da speziell Einfamilienhäuser analysiert werden sollen. Ihre Anzahl liefert wertvolle Informationen über das potenzielle Wachstum der Nutzung von PV-Paneelen und Wärmepumpen.
- Das Verhältnis zwischen diesen beiden Merkmalen, da dieses potenziell Hinweise auf die dominierenden Netzstrukturen in der Region liefert.

- Die Einwohnerzahl, da sie zusätzlich zu den Wohnungsdaten eine Schätzung des Energieverbrauchs ermöglicht.

Während es sich bei den oben genannten Merkmalen um Skalare handelt, welche unmittelbar den verfügbaren Datenquellen entnommen werden können, ist die Extraktion relevanter Merkmale aus Zeitreihen, wie beispielsweise Wetterzeitreihen, schwieriger.

Um aus den komplexeren Zeitreihen vergleichbare Merkmale zu extrahieren, wurden gebräuchliche deskriptive statistische Beschreibungsmerkmale herangezogen, wie beispielsweise der Mittelwert, die Standardabweichung, das 10- oder 90-Prozent-Quantil sowie Werte der Autokorrelation. Außerdem wurden in Normen oder Auslegungsheuristiken angewendete Beschreibungsmerkmale abgeleitet. Dazu zählen beispielsweise die Normaußentemperatur, die Heizgradstunden und die Sonnenscheingradstunden.

Allerdings gehen durch diese Reduktion auf deskriptive statistische Merkmale notwendigerweise dynamische Zusammenhänge verloren. Um zumindest gewisse jahreszeitliche Aspekte zu erhalten, wurden die Beschreibungsmerkmale außerdem auf Basis kleinerer Unterabschnitte der Gesamtzeitreihe gebildet. Innerhalb der Energietechnik ist bei der Wahl der Unterabschnitte eine Aufteilung mittels eines Drei-Jahreszeiten-Systems verbreitet. Das Jahr wird entsprechend in eine Winter-, eine Sommersaison sowie eine Übergangssaison, welche den Frühling und den Herbst umfasst, aufgeteilt.

Insgesamt wurden auf diese Weise 52 Merkmale abgeleitet. Diese Anzahl stellt für Cluster- Algorithmen grundsätzlich eine hohe Komplexität dar. Aus diesem Grund wurde der Cluster- Algorithmus *sparse k-means* angewendet, welcher es erlaubt, Merkmale, welche sich für das Clustering als weniger nützlich erweisen, geringer zu gewichten. Die Gewichtung kann dabei auch null annehmen, sodass einige Merkmale beim Clustering unberücksichtigt bleiben.

Im Ergebnis wurden durch den Algorithmus unter anderem folgende Merkmale ausgeschlossen: Werte der Autokorrelation, Heiz- und Sonnenscheingradstunden, Normaußentemperatur sowie das Verhältnis zwischen Einfamilienhäusern und Gesamtgebäudezahl. Diesem Ausschluss folgend wurden die in Tabelle 4-1 aufgelisteten Merkmale berücksichtigt.

Tabelle 4-1: Übersicht relevanter Merkmale zur Durchführung der Cluster-Analyse

Strukturelle Merkmale:	Saisonale, deskriptive Merkmale von Temperatur, Global- und Direktstrahlung:
Einwohnerzahl	Arithmetisches Mittel
Gesamtgebäudezahl	Standardabweichung
Zahl der Einfamilienhäuser	10- (nur Temperatur) sowie 90-Pozent-Quantil

4.3 Anwendung der Merkmale zur Identifikation repräsentativer Kontexte mittels Clustering

Mittels Clustering sollen für die unterschiedlichen Landkreise und kreisfreien Städte Ähnlichkeiten zwischen den regionalen Gegebenheiten identifiziert werden. Die Landkreise werden im Ergebnis einer a priori nicht definierten Anzahl an Clustern zugeordnet, welche die unterschiedlichen Kontexte beschreiben. Ziel eines Clusteralgorithmus ist, jedes einzelne Cluster so homogen und die unterschiedlichen Cluster so heterogen wie möglich zu gestalten. Außerdem ist wünschenswert, dass eine möglichst konsistente, das heißt bei mehreren Durchführungen des Clustering identische Zuordnung der jeweiligen Landkreise zu den unterschiedlichen Clustern erfolgt. Ausschlaggebend dafür ist zum einen die Wahl und Implementierung des Clusteralgorithmus, welcher die Homo- und

Heterogenität erkennen und zuordnen muss. Zum anderen ist die Auswahl und Darstellung der Feature relevant, welche die Homo- und Heterogenität selbst beschreiben.

Als Clusteralgorithmen wurden *k-means*, *sparse k-means* und *k-medoids* getestet. Sparse k-means bietet den Vorteil, dass der Algorithmus selbst Feature eliminiert, die dem Clustering nicht zuträglich sind. Das Clustering wurde jeweils mit einer Clusteranzahl zwischen 5 und 34 Clustern durchgeführt und 50-mal wiederholt. Für die Beurteilung der Ergebnisqualität wurde der *adjusted Rand index* herangezogen, welcher die oben beschriebene Konsistenz des Clusterings beschreibt.

Der adjusted Rand index geht für alle Algorithmen von etwa 1 im Falle von 5 Clustern auf etwa 0,5 im Falle von 34 Clustern zurück. Wesentliche Unterschiede sind nicht erkennbar. Um den Nutzen einzelner Features und unterschiedliche Repräsentationen zu testen, wird daher der sparse k-means Algorithmus angewendet und das finale Clustering mit k-means durchgeführt.

Ein erster Blick auf die durch den sparse k-means Algorithmus gewählten Gewichtungen offenbart, dass – abgesehen von der Bevölkerungszahl – nicht-wetterbezogene Features mit Werten von null oder nahe null gewichtet wurden. Mit anderen Worten, das Ergebnis des Clusterings beruht – erneut abgesehen von der Bevölkerungszahl – ausschließlich auf wetterbezogenen Features.

Weitere Bemühungen, die Konsistenz des Clustering durch andere Repräsentationen oder durch eine Reduktion der Features zu erreichen, waren nicht erfolgreich. Ebenso wenig konnte anhand einer Analyse der GAP-Statistik in dem gewählten Suchraum zwischen einem und 300 Clustern eine eindeutig optimale Clusteranzahl identifiziert werden. Die Entscheidung für 15 Cluster ist daher nicht eindeutig und sollte nicht überinterpretiert werden.

Die finale abschließende Zuordnung der Landkreise zu den 15 Clustern und der jeweilige Landkreis, der den Clusterzentren am nächsten lag, die Repräsentanten der Cluster, sind in Tabelle 4-2 und grafisch in Abbildung 4-1 dargestellt.

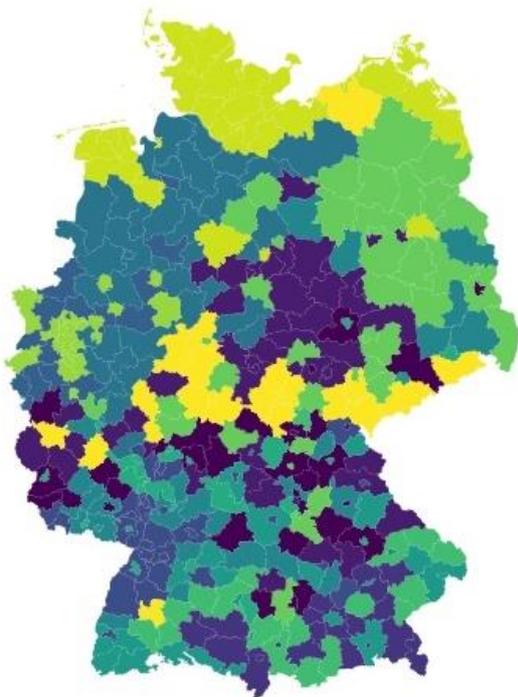


Abbildung 4-1: Deutsche Landkreise und kreisfreie Städte in 15 Clustern

Tabelle 4-2: Finale Zuordnung der Landkreise und kreisfreien Städte (NUTS 3-Ebene) zu 15 Clustern mit hervorgehobenen Repräsentanten der Cluster.

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
	3102													
	3154													
	3155													
	3158													
	3252				3151									
	3254				3157					3103				
	3354				3159					3153				
	6436		6411		3251					3351				
5366	6533		6414		3255					3360			1001	
6412	6534		6432		3256					6440			1002	
6435	6636		6433		3257	6437				6531			1003	
7133	7131		7311		3352	7134				6611	5111		1004	
7235	7135		7314		3353	7137	7317			6632	5112		1051	
7312	7141		7316		3355	7335	8115	6413		7138	5113		1053	
7333	7231		7318		3356	7336	8117	6431		9461	5114		1054	6434
8127	7232	8426	7332		3357	7340	8119	6438	8135	9478	5116		1055	6532
9361	9176	8436	7334		3358	8118	8315	7111	8326	9574	5117		1056	6535
9373	9273	8437	7337	4011	3359	8126	8335	7211	8327	9576	5119		1057	6631
9375	9372	9163	7338	5162	3361	8136	8336	7313	8415	9672	5122		1058	6633
9463	9374	9172	8116	5166	3404	8225	8337	7315	8417	9772	5124		1059	6634
9471	9377	9174	8121	5170	3453	8226	8421	7319	8425	12053	5154		1060	6635
9472	9464	9175	8125	5334	3454	8316	8435	7320	9171	12060	5158		1061	7140
9473	9563	9179	8212	5358	3456	8416	9162	7331	9173	12061	5314		1062	7233
9474	9575	9182	8215	5362	3459	9186	9185	7339	9177	12062	5315	2000	8325	
9476	9675	9183	8216	5382	3460	9263	9187	8111	9180	12063	5316	3241	3101	13072
9562	9676	9184	8221	5554	3461	9371	9261	8128	9181	12064	5370	11000	3401	14521
9564	9678	9188	8222	5562	5120	9477	9262	8211	9182	12065	5378		3402	14523
9577	9773	9189	8231	5754	5374	9572	9271	9362	9272	12066	5378		3403	14628
9671	12051	9190	8235	5770	5558	9662	9275	9462	9276	12068	5512		3405	16054
9673	12054	9274	8236	5974	5566	9779	9376	9573	9277	12069	5513		3451	16066
9677	14730	9279	8237	5978	5570	10043	9479	9661	9278	12070	5515		3452	16067
9761	15001	9762	8311		5758	10045	9571	9674	9565	12071	5711		3455	16069
9771	15003	9763	8317		5762	12066	9679	9775	9777	12072	5774		3457	16070
9774	15082	9780	9161		5766	12067	9764	14612	9778	12073	5911		3458	16075
10042	15083		9178		5954	14625	9776	15002	16072	13071	5913		3462	16076
10046	15084		9363		5958	14627	14511			14524	5914		4012	
12052	15085		9475		5962	15081				14626	5915		13003	
14522	15087		9561		5966	15086				14713	5916		13004	
15088	15089		9663		5970					14729			13073	
16055	16051		10041		6439					15090			13074	
	16053		10044		7132					15091			13075	
	16056				7143					16052				
	16062				13076					16056				
	16063				16061					16068				
	16064									16073				
	16065									16077				
	16071													
	16074													

4.4 Anwendung kontextueller Charakteristika

Um eine Einschätzung der Cluster-Ergebnisse liefern zu können, wurde eine Plausibilitätsprüfung einzelner Cluster und deren Mitglieder vorgenommen. Beispielsweise ist in Abbildung 4-1 an Schleswig-Holstein oder Brandenburg gut erkennbar, das zusammenhängende Regionen überwiegend einem Cluster zugeordnet werden. Ebenso sind größere Ballungsräume dieser Region in Cluster 13 (Hamburg, Hannover, Berlin) zusammengefasst. Außerdem scheinen sich Mittelgebirgskreise in Mitteldeutschland (von Eifel, Hunsrück, Taunus bis Rhön und Erzgebirge) in Cluster 15 zu sammeln. Es scheint daher durchaus plausibel, dass Ähnlichkeiten hinsichtlich der meteorologischen Rahmenbedingungen innerhalb der 15 Cluster abgedeckt sind.

Offen ist, ob mittels dieser unterschiedlichen meteorologischen Gegebenheiten auf unterschiedliche Potenziale von PtX-Technologien geschlossen werden kann. Eine Herausforderung stellt dar, dass sich für die Nutzung und das Ausgleichspotenzial von PtX-Technologien relevante Parameter aufgrund von vielfältigen Faktoren zwischen den Landkreisen innerhalb Deutschlands unterscheiden. Beispielhaft für das Vorhandensein oder den Zubau von PV-Anlagen sei neben unterschiedlichen Globalstrahlungswerten als Einflussfaktoren an dieser Stelle die öffentliche Förderung und politische Kultur im zugehörigen Bundesland oder Landkreis, regionales Engagement und der durchschnittliche sozioökonomische Status der Bewohner*innen genannt. Entsprechend ist die Verbreitung von PV-Anlagen bisher aus vielen weiteren als den meteorologischen Gründen verschieden.

Ähnlich verhält es sich mit Gegebenheiten hinsichtlich der Verteilnetze und Netzstrukturen innerhalb der Region. Auch diese mögen innerhalb eines NUTS3-Kreises sehr divers sein und sich auch bei gleicher Bevölkerungszahl und -verteilung aufgrund von historischen Entwicklungen und Zuständigkeiten unterschiedlicher Übertragungs- und Verteilnetzbetreiber divergieren.

Zuletzt sei angemerkt, dass sich auch die über die NUTS3-Ebene definierten Landkreise strukturell beispielsweise im Hinblick auf Fläche (zwischen 35 und 5 500 km²) oder Einwohnerzahl (zwischen 36 000 und 3 600 000) stark unterscheiden. Auch dies erschwert eine kreisübergreifende Einordnung und Analyse. Ein Wechsel auf andere regionale Bezugsebenen wäre denkbar, wird jedoch durch die geringe Datenverfügbarkeit erschwert.

Aufgrund dieser vielfältigen Herausforderungen ist es im Rahmen des Projekts nicht gelungen, eine stichhaltige und skalierbare kontextbasierte Bewertung unterschiedlicher Ausgleichspotenziale innerhalb Deutschlands durchzuführen. Weitere Arbeiten im Hinblick auf die Verteilung von Netzspezifika (beispielsweise durch die gewählten Auslegungen oder räumliche Verteilung der Hausanschlusspunkte) und Netzstrukturen innerhalb der Landkreise sind notwendig. Die hohe Dynamik in den Bereichen Digitalisierung (bspw. Erfassung und Verfügbarkeit von Daten) sowie Dekarbonisierung (bspw. Wärmewende und Verkehrswende) lassen hoffen, dass sich zu dieser Fragestellung neue Analyse- und Auswertungsmöglichkeiten eröffnen.

5 Modellierung der Regelung von Ausgleichstechnologien

Wichtige Aspekte für den netz- und systemdienlichen Einsatz von Sektorenkopplungstechnologien sind die gewählten Regelungsansätze und damit einhergehend die Informations- und Kommunikationstechnologien (IKT). Im folgenden Kapitel werden zunächst grundlegende Konzepte hinsichtlich zentraler und dezentraler Regelung mit unterschiedlichen Wissenshorizonten beleuchtet.

Im weiteren Verlauf werden Ansätze zur Abbildung der Regelungs- und Kommunikationsstrategien in Dymola/Modelica mit Fokus auf die unteren Netzebenen und unter Verwendung des im Projekt IntegraNet entwickelten *GridConstructors* untersucht. Die Ansätze werden dabei anhand von Minimalbeispielen verglichen. Im letzten Abschnitt liegt der Fokus auf den höheren Netzebenen mit entsprechend größeren Systemen. Es wird die im Rahmen des Projektes entwickelte Bibliothek zur automatischen Erstellung großer Systeme in Dymola vorgestellt und auf die benötigten und implementierten Regelungsschnittstellen eingegangen.

5.1 Grundlagen/Konzepte

Bei der Regelung von Energiesystemen kann grundsätzlich zwischen zwei verschiedenen Regelungsansätzen unterschieden werden. Die dezentrale Regelung basiert auf einer verteilten Architektur. Jede Anlage/Anlagenverbund bzw. jeder Verbraucher hat eine eigene Regelung. Bei der zentralen Regelung dagegen erfolgt die Regelung von einer zentralen Einheit aus, die Informationen von den Einzelsystemen bekommt, diese auswertet und Steuerungssignale zurückgibt. Im aktuellen

Energiesystem erfolgt die Regelung auf Verteilnetzebene in der Regel dezentral in den Haushalten (z. B. das Zusammenspiel zwischen Aufdach-PV-Anlagen, Batteriespeichern und Verbrauch). Jeder Haushalt hat eine oder mehrere eigenständige Regelungen, entweder die anlageninternen Regelungen oder aber SmartHome-Systeme, mit denen innerhalb des Haushalts die Geräte vernetzt werden.

Bei größeren Anlagen kommen zentrale Regelungen hinzu. Jede Anlage hat zwar weiterhin die interne Steuerung, die Netzbetreiber haben aber teilweise Möglichkeiten, ein An- oder Abfahren einzelner Anlagen z. B. aus Gründen der Netzsicherheit anzufordern. In Hochspannungsnetzen werden, um Engpässe zu vermeiden, die Spannung, Frequenz und Lastverteilung zentral geregelt.

Mit der zunehmenden Dezentralisierung der Erzeugung, insbesondere durch PV-Anlagen und den steigenden Anteilen an E-Mobilität, wächst auch die Bedeutung der Vernetzung der Systeme auf Verteilnetzebene. Abhängig vom Grad der Vernetzung bzw. dem Wissenshorizont der Regelungssysteme sind unterschiedliche Varianten innerhalb der klassischen Einteilung denkbar. Einige dezentrale Regelungsansätze werden im Hinblick auf den Wissenshorizont und die Ziele in Tabelle 5-1 kurz vorgestellt.

Tabelle 5-1: Unterschiedliche Ausprägungen von dezentralen Regelungsansätzen mit zunehmendem Wissenshorizont

	Regelungsansatz	Beschreibung
 Zunehmender Wissenshorizont	Anlagenregelung	Jeweils anlageninterne Regelung ohne Wechselwirkung zwischen unterschiedlichen Technologien. Regelung bekommt keine externen Informationen. Aktuell in der TransiEnt-Library im Modell <i>IndependentTechnologies</i> umgesetzt.
	Einzelssystemregelung Smart Home	Vernetzung mehrerer Technologien innerhalb eines Haushaltes. Den Regelungssystemen stehen Informationen über Wärmebedarf, Strombedarf, Anwesenheit, aktuelle Erzeugung (PV, KWK) etc. zur Verfügung. Hierunter fallen Anwendungen wie Smart Home oder Smart Monitoring. Ausgleichsziele sind Senkung des Verbrauchs, Eigenkostenminimierung/ Eigenverbrauchsminimierung oder Emissionsminderung des Einzelhaushaltes
	Einzelssystem- regelung +	Wie Einzelssystemregelung, aber mit zusätzlichen Informationen von außen (z.B. Wettervorhersage, Strompreis, Netzzustand am Netzanschlusspunkt). Auf Basis der Informationen kann ein optimierter Anlagenbetrieb anhand von Prognosen angestrebt werden. Mögliche Ziele der Regelung sind Netzdienlichkeit oder eine Erhöhung der Wirtschaftlichkeit über die Nutzung von Marktpreisunterschieden
	System- Kommunikation	Die Einzelssysteme bekommen weitere Informationen aus dem Quartier. Es sind Informationen über die Anlagentopologie und Netzmerkmale innerhalb des Quartiers vorhanden. Ziel ist eine Quartiersoptimierung und nicht mehr die reine Einzelssystemoptimierung. Ausgleich von lokalen Spannungsspitzen innerhalb des Quartiers, Minimierung von Residuallastspitzen, Gesamtkostenminimierung.

Auch bei dem dezentralen Regelungsansatz mit den meisten verfügbaren Informationen (“System-Kommunikation“) kann die Regelung der Einzelssysteme keine benachbarten Systeme beeinflussen. Sie empfängt zwar Informationen zum Anlagenstatus von dort und gibt eigene Informationen weiter, sendet aber keine Steuersignale zurück.

Im Gegensatz dazu können mit einer zentralen Regelung Sollwertvorgaben bzw. Stellgrößenvorgaben an alle Akteure bzw. Anlagen gesendet werden. Auch bei der zentralen Regelung sind verschiedene Abstufungen der verfügbaren Informationen und der Komplexität der Regelung möglich. Neben einfachen Varianten, in denen auf direkte Abweichungen von Sollwerten (z.B. Spannungsbandverletzungen, o.ä.) reagiert wird, sind auch komplexere Optimierungsalgorithmen möglich, in die z. B. auch Prädiktionen von Randbedingungen einfließen. Insbesondere im Hinblick auf die Rechenzeit bietet die zentrale Regelung hier Vorteile, da die Optimierungsrechnung nur einmal zentral ausgeführt werden muss und nicht dezentral verteilt bei jedem Akteur. Ziele einer zentralen Quartiersregelung können Primärenergieeinsparungen, Spannungshaltung/Residuallast Spitzenkappung, Gewinnmaximierung (aus Betreibersicht), Ausgleich von lokalen Spannungsspitzen oder Emissionsminderung sein. Aktuell werden zentrale Regelungen vornehmlich auf höheren Netzebenen, bzw. bei größeren Anlagen eingesetzt, z. B. bei der Planung von Kraftwerksfahrplänen. In Quartieren werden zentrale Regelungen zum aktuellen Zeitpunkt in der Regel noch nicht eingesetzt. Hierzu müssten die Einzelhaushalte die Kontrolle über die individuelle Versorgung insb. auf Wärmeseite abgeben. Langfristig sind aber (im begrenzten Maße) zentrale Regelungseingriffe zu erwarten, da aktuell bereits die benötigten regulatorischen Rahmenbedingungen geschaffen werden. So sehen die von der Bundesnetzagentur Ende November 2023 vorgestellten Regelungen zur Integration von steuerbaren Verbrauchseinrichtungen, wie Wärmepumpen oder Lademöglichkeiten für E-Autos, Möglichkeiten zur Abregelung der Verbraucher durch den Netzbetreiber bei drohender Überlastung des Netzes vor [26].

In der Umsetzung kann die Kommunikation zwischen unterschiedlichen Akteuren sowie die Informationsweitergabe zur Regelung von zentraler Stelle über unterschiedliche Busprotokolle (CAN-Bus, Modbus, o.ä.) erfolgen. Um diese Kommunikation auf Modellebene abzubilden, sind verschiedene Ansätze möglich. Innerhalb der Dymola/Modelica-Umgebung können Informationen über Busverbindungen zwischen den verwendeten Modellkomponenten ausgetauscht werden, bzw. an einen entsprechenden Regelungsbaustein weitergegeben werden. Handelt es sich um komplexere Algorithmen zur Optimierung der Betriebsführung kann es sinnvoll sein, diese Optimierung außerhalb von Modelica durchzuführen. Das Anwenden solcher Algorithmen ist über sogenannte Functional Mock-Up Interfaces (FMI) und externe Programme, wie z. B. Python möglich. Hierbei können in Python alle Signale des Simulationsmodells verwendet werden. Die Implementierung einer Informationsbusstruktur ist daher nicht zwingend notwendig. Dafür müssen für die Stellgrößen entsprechende Schnittstellen im Modell vorgesehen werden, über die die extern berechneten Regeleingriffe an das Modell weitergegeben werden.

In Abschnitt 5.2 werden Beispiele für die modelltechnische Umsetzung der Kommunikation auf Quartiersebene für diese unterschiedlichen Ansätze vorgestellt. Dabei wird zunächst auf die Einzelsystem-Regelung eingegangen und anschließend werden drei verschiedene Regelungsansätze (dezentral und zentral) verglichen: eine regelbasierte Regelung innerhalb von Dymola, bestärkendes Lernen (engl. Reinforcement-Learning) und eine modellprädiktive Regelung (engl. Model Predictive Control, kurz MPC).

5.2 Modellierung der Regelung auf *GridConstructor*-Ebene

Im Modell *IndependentTechnologies*, das im Rahmen des Projektes *IntegraNet* erstellt wurde, wurden die Technologien bisher weitgehend unabhängig voneinander geregelt, da der Schwerpunkt auf der einfachen Parametrisierung und Austauschbarkeit der Technologien lag. Wird die Regelung von Sektorenkopplungstechnologien in den Vordergrund gestellt, wird eine Vernetzung der Technologien notwendig. Dafür wurde eine Variation des bestehenden Modells, das Modell *ConnectedTechnologies*, erstellt. Es enthält zusätzliche Schnittstellen, sodass die Technologien von außen angesteuert werden und auch untereinander Informationen austauschen können.

5.2.1 Dezentrale Einzelsystem-Regelung

Um dezentrale Regelungen von Einzelsystemen, also „Smart Homes“, abzubilden, wurde das Modell *IndependentTechnologies* angepasst. Das Modell beinhaltet alle Technologien, um den Energiebedarf, -bezug und die Energiespeicherung eines Gebäudes abzubilden. Als Flexibilitäten werden die Regelungen der Nachtspeicherheizungen, Wärmepumpen, BHKWs, Batterien und die Regelung der Ladevorgänge der Elektroautos identifiziert.

Im Modell *IndependentTechnologies* haben die Technologien voneinander unabhängige Regelungen. Die Nachtspeicherheizung wird ohne explizite Regelung über das eingelesene Lastprofil abgebildet. Eine Flexibilisierung von Nachtspeicherheizungen ist grundsätzlich möglich, aufgrund der rückläufigen Anzahl und großer technischer und regulatorischer Hürden [27] wurde in diesem Projekt jedoch keine Regelung für diese Technologie implementiert. Für die Ladevorgänge von Elektroautos wurden, wie in Kapitel 3 beschrieben, Schnittstellen zur Regelung implementiert und eine netzorientierte Regelung umgesetzt. Beim BHKW stehen Regler mit zwei verschiedenen Regelungsstrategien zur Auswahl: ‚wärmegeführt‘ und ‚Orientierung am Strompreis‘. Für die Wärmepumpe gibt es zusätzlich die Option, sie orientiert an der eigenen PV-Erzeugung zu regeln. Für BHKWs wurde daher ein Controller *Pvoriented* ergänzt, der das Ziel hat, die Stromproduktion der Anlage in Zeiten zu verschieben, in denen wenig Photovoltaikstrom produziert werden kann. Die Batterie wird im bisherigen Modell bedarfsorientiert geregelt: Ist der Strombedarf geringer als der durch die Photovoltaik erzeugte Strom, wird die Batterie geladen. Die Entladung der Batterie findet statt, wenn der Strombedarf größer als der erzeugte Strom ist. Der Strombedarf setzt sich zusammen aus dem Strombedarf für elektrische Geräte und für die Trinkwasserversorgung, jedoch nicht aus dem Strombedarf für Heiztechnologien. Für den Strombedarf wird der Strom, der nicht zum Heizen verwendet wird und der Strom zur elektrischen Warmwasserbereitung berücksichtigt. Hier wurde ein Controller *MaxSelfCons_connected* ergänzt, der auch den Strombedarf und die Stromerzeugung der Heizungstechnologien berücksichtigt und ein weiterer *MaxSelfCons_PriceLed_connected*, der den Strompreis mit einbezieht. Die ergänzten Regler sollen langfristig in die TransiEnt-Bibliothek aufgenommen werden.

Für die neuen Batterieregelungen erhält jeder modellierte Stromerzeuger und -verbraucher einen Output, der die aktuelle erzeugte oder bezogene Leistung an den Batterie-Controller weitergeben kann. Der bereits vorhandene Batterie-Controller, der als Zielgröße die Maximierung des Eigenbezugs des Photovoltaikstroms hat, wurde so angepasst, dass als Stromerzeuger neben der Photovoltaikanlage auch ein BHKW berücksichtigt werden kann. Als mögliche Stromverbraucher werden die bezogenen Leistungen von Wärmepumpe P_{HP} und Nachtspeicherheizung P_{NSH} zusätzlich zum Haushaltsstrom $P_{Consumer}$ aufgenommen (siehe Abbildung 5-1). Wie in der Abbildung dargestellt, wird die Ladeleistung der Batterie über die Differenz der aktuellen Erzeugerleistung und der Leistung aller Verbraucher über eine vorgegebene Soll-Ladeleistung P_{set} geregelt. Der produzierte Strom besteht aus dem von der Photovoltaikanlage produzierten Strom P_{PV} und vom BHKW produzierten Strom P_{CHP} .

In die Regelung an sich gehen jeweils immer nur die Werte der für das jeweilige Gebäude konfigurierten Technologien ein. Dies ist, wie bisher auch, flexibel über die Eingabemaske im *GridConstructor* parametrierbar. Zusätzlich wurde eine Variante des Controllers erstellt, bei der ein Grenzwert für den Strompreis angegeben werden kann, sodass beispielsweise bei einem hohen Strompreis überschüssiger Strom nicht in die Batterie, sondern zu diesem Preis ins Stromnetz eingespeist wird. Diese Regelungsstrategie findet nur bei einem variablen Strompreis für Endkunden Anwendung.

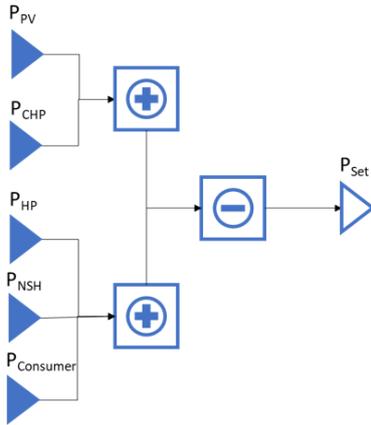


Abbildung 5-1: Schema der Sollwertberechnung des erweiterten Batterie-Controllers.

In Tabelle 5-2 ist ein Vergleich des Eigenverbrauchs, des Netzbezugs und der Stromkosten für die unterschiedlichen Regelungsstrategien der Batterie eines Einfamilienhauses mit einem jährlichen Heizwärmebedarf von ca. 15 000 kWh dargestellt. Das Gebäude ist zusätzlich zur Batterie mit einer Wärmepumpe als Heiztechnologie und Photovoltaik ausgestattet. Stromkosten und Einspeisevergütung entsprechen dem Strommarktpreis. Durch die Einbeziehung des Leistungsbezugs der Wärmepumpe in die Regelung der Batterie *MaxSelfCons_connected* lässt sich der Netzbezug im Vergleich zur ursprünglichen Regelung *MaxSelfCons* um fast 10 % reduzieren, wobei die Stromkosten nur leicht sinken. Daraus lässt sich schließen, dass hauptsächlich zu Zeiten niedriger Strompreise Photovoltaikstrom zusätzlich selbst verbraucht werden konnte. Die strompreisorientierte Regelung *MaxSelfCons_PriceLed_connected* führt zu einem Netzbezug, der zwischen dem der beiden anderen Regelstrategien liegt. Im Vergleich zum Regler *MaxSelfCons_connected* verringern sich die Stromkosten um fast 7 %.

Tabelle 5-2: Vergleich der Batterieregelung für ein Gebäude.

Regelungsmodell	PV Produktion in $\frac{kWh}{a}$	Eigenverbrauch in $\frac{kWh}{a}$	Netzbezug in $\frac{kWh}{a}$	Stromkosten in $\frac{€}{a}$
<i>MaxSelfCons</i>	5042	1664	6093	137
<i>MaxSelfCons_connected</i>	5042	2247	5510	135
<i>MaxSelfCons_PriceLed_connected</i>	5042	1680	6077	126

5.2.2 Zentrale Regelung

Zur Abbildung von zentralen Regelungsansätzen in Dymola sind weitere Schnittstellen notwendig, um die Kommunikation zwischen der zentralen Regelungseinheit und den Verbrauchern und Erzeugern abzubilden. Zur Weitergabe der Regelungssignale an die Technologien in den Gebäuden und zum Austausch von Signalen wird ein expandable Connector als Control Bus in das Modell *ConnectedTechnologies* integriert. Um die Signale von der obersten Modellebene an das Modell *ConnectedTechnologies* weiterzugeben und umgekehrt, wird ein solcher Signal Bus analog zu den *Port*-Modellen auch in die Modelle *GridConstructor* und *GridElement* integriert, wie in Abbildung dargestellt. Auf oberster Modellebene können die Signale übergeben werden, entweder an und von einem Regelungsmodell innerhalb von Modelica oder über einen externen Algorithmus (z. B. über eine Functional Mock-up Unit (FMU) an eine Optimierung in Python). Bei größeren Modellen ist die

händische Zuordnung der Signale umständlich, deswegen wird die Zuordnung über ein Skript gelöst, das als Input alle zu übergebenden Variablen erhält und die *Connect*-Statements ausgibt.

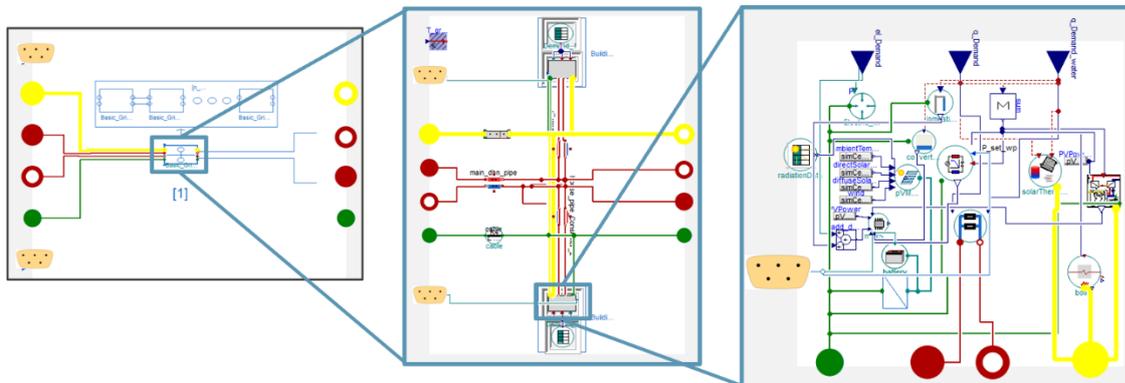


Abbildung 5-2: Darstellung der grafischen Oberfläche der Komponenten *GridConnector*, *GridElement* und *ConnectedTechnologies* (von links nach rechts).

Die Erweiterung um den Control Bus wird durch die Umsetzung einer einfachen zentralen Regelung in Modelica erprobt: Die Residuallast und der State of Charge (SOC) der Batterien werden als Input verwendet, um das Laden und Entladen der Batterien in den Gebäuden so zu regeln, dass die Aufteilung der Residuallast auf die Batterien antiproportional zum Füllstand der Batterien erfolgt.

Um auch außerhalb von Modelica umgesetzte Regelungsansätze für die Simulationen nutzen zu können, wurde das Functional Mock-up Interface (FMI) verwendet. Dieses ist ein Standard, der den Austausch von modellbasierten dynamischen Systemmodellen ermöglicht und von Dymola unterstützt wird [28]. Für die Programmierung der Regelungsalgorithmen außerhalb von Modelica wurde Python aufgrund seiner umfangreichen Bibliotheken und einfachen Lesbarkeit gewählt. Mithilfe der Python-Bibliothek *PyFMI* wurden die erstellten FMUs in Python geladen und angesprochen.

Zur vereinfachten Integration der Regelungsstrategien und den FMUs wurde eine Python-Bibliothek *pycontrolfmu* entwickelt, die es erleichtert, Regelungsalgorithmen mit den Modelica-Modellen zu koppeln. Darin stehen Funktionen zur Verfügung, die für die schrittweise Simulation oder auch zur Visualisierung genutzt werden können. Verschiedene Regelungsalgorithmen können jeweils als neues Modul hinzugefügt werden. Für jedes erstellte FMU wird auch eine YAML-Datei, die als Konfigurationsdatei dient, erzeugt. Sie enthält unter anderem die Definition der Eingangsvariablen sowie eine kurze Modellbeschreibung. Die Bibliothek soll auch in anderen Forschungsprojekten, bei denen komplexere Regelungsstrategien angewendet werden, Verwendung finden.

Mit dieser Modellbibliothek wird es möglich, benutzerfreundlich verschiedene Regelungsstrategien auf demselben Simulationsmodell zu evaluieren, ähnlich OpenAI Gym.

5.2.3 Vergleich dezentraler und zentraler Regelungsansätze

Zur Erprobung werden Regelungskonzepte für Batteriespeicher umgesetzt und angewandt. Implementiert wird zur Validierung zunächst eine regelbasierte dezentrale Regelung in Python, die als Benchmark genutzt wird und entsprechend der eigenbedarfsoptimierten Regelung in Modelica, wie oben beschrieben, funktioniert. Zur optimierten Betriebsführung der Batterien wird eine prädiktive Regelung mithilfe von bestärkendem Lernen (Reinforcement-Learning) umgesetzt. Die Implementierung erfolgt mit der Python-Bibliothek *stable-baselines*, explizit wird der Algorithmus PPO2 verwendet. Trainiert wird auf einen Zeitraum von 3 Wochen und stündlicher Zeitauflösung. Der festgelegte Wissenshorizont (Vorhersagezeitraum) des Modells beträgt 24 Stunden in die Zukunft. Minimiert werden soll der Strombezug aus dem externen Netz für ein Quartier. Daten, die dem

Modell als Grundlage zur Optimierung übergeben werden, sind die Residuallast des betrachteten Quartiers und der einzelnen Gebäude, der Speicherstand der Batterien, die Außentemperatur und die direkte solare Einstrahlung. Zum Vergleich wird zudem ein in einem anderen Projekt (EnQM, FKZ 03ET1417A) implementierter Regelungsansatz, der einen Model-Predictive-Control Algorithmus verwendet, genutzt.

Auf ein kleines Quartier, bestehend aus elf Gebäuden, wovon acht mit Photovoltaik und Batterien ausgestattet sind, werden beispielhaft die drei erläuterten Regelungsansätze zum optimierten Betrieb der Batterien angewendet (siehe Abbildung 5-3). Sie werden in Bezug auf die Laufzeit der Simulation und die Reduktion des Netzbezuges des Quartiers betrachtet.

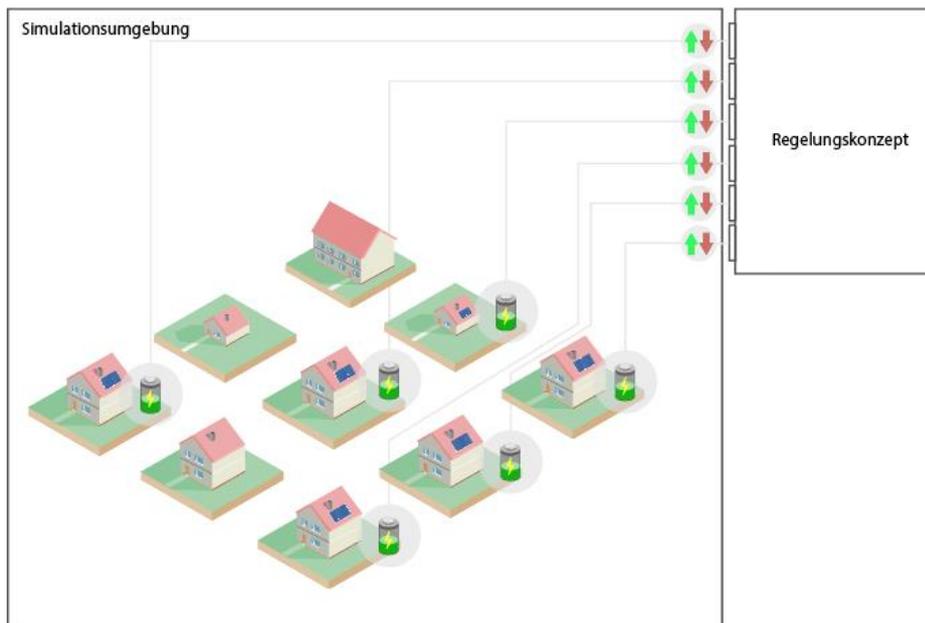


Abbildung 5-3: Schematische Darstellung des Quartiers

In Tabelle 5-3 sind die Ergebnisse dargestellt. Die MPC-Regelung benötigt die längste Rechenzeit, liefert jedoch auch das beste Ergebnis. Auch durch die Reinforcement Learning-Regelung kann eine leichte Reduktion des Strombezugs erzielt werden. Somit eignet sich die MPC-Regelung gut, wenn Rechenzeit kein kritischer Faktor ist. Bei sehr großen Modellen und zeitkritischen Simulationen wäre eine einfache regelbasierte Regelung oder ggf. auch die Reinforcement-Regelung sinnvoller einsetzbar.

Tabelle 5-3: Netzbezug des Quartiers und Rechenzeit der Varianten im Vergleich.

Modell	CPU Time in s	Netzbezug in MWh/a
Ohne Batterie (Dymola/Modelica)	46	52,5
Dezentrale Einzelsystemregelung		
- Dymola/Modelica	167	48,5
- Python	333	49,5
Zentrale Regelung mit MPC	1461	47,5
Zentrale Regelung mit Reinforcement Learning	207	49,3

5.3 Umsetzung der Regelung beim zellulären Ansatz

Im Rahmen dieses Projektes wird die Sektorenkopplung aus regionaler Perspektive betrachtet. Der *GridConstructor* eignet sich gut zur Abbildung und Simulation von Straßenzügen und Quartieren bis hin zu Städten unterschiedlicher Größe. Für die Untersuchung größerer Regionen bietet sich jedoch ein stärker aggregierendes Modell an, das bei einem zellulären Ansatz jeweils eine Energiezelle abbildet. In der TransiEnt-Bibliothek gibt es dafür das Package *Superstructure*, das im Rahmen des Projektes ResiliEntEE [29] entwickelt wurde. Das Modell enthält für alle Erzeuger, Verbraucher und Speicher in einer Zelle, deren Größe beliebig festgelegt werden kann, jeweils ein Modell zur aggregierten Abbildung der Technologien. Für die Simulationen im Rahmen des Integranet II Projektes wird eine vereinfachte Version der *Superstructure* verwendet, die nicht auf Portfolios mit Records zurückgreift, sondern direkt mithilfe von Python parametrisiert wird.

Das vereinfachte *Superstructure*-Modell enthält Verbraucher-Zeitreihen für den Strom- und Wärmebedarf der Sektoren Wohnen, GHD und Industrie, deren Erzeugung in Kapitel 6.4 beschrieben wird. Zur Deckung des Wärmebedarfs werden die Technologien Gaskessel, Kraft-Wärme-Kopplung und Wärmepumpen abgebildet, die leitungsgebundene Energieträger zur Wärmebereitstellung nutzen. Übrige Heiztechnologien, die beispielsweise mit Biomasse betrieben werden, werden bilanziell bei der Erstellung der Lastprofile berücksichtigt, aber nicht explizit modelliert. Die Erzeuger werden in die beiden Kategorien ‚erneuerbare Erzeuger‘ und ‚konventionelle Erzeuger‘ aufgeteilt und über Lastprofile eingebunden. Als erneuerbare Energien werden Photovoltaik, Windkraftanlagen, Biomasseanlagen und Laufwasserkraftwerke berücksichtigt. Für die konventionelle Stromerzeugung finden Gas-, Braunkohle-, Steinkohle- und Ölkraftwerke sowie Müllverbrennungsanlagen Berücksichtigung. In den Kapiteln 6.2 und 6.3 wird das Vorgehen zur Erzeugung der Lastprofile für Photovoltaik und Windkraftanlagen erläutert, Informationen zu den übrigen Profilen finden sich in Kapitel 8.1. Als Ausgleichstechnologien werden Batteriespeicher und Elektrolyseure eingesetzt. Zur Übergabe der Regelungssignale wird analog zum Vorgehen beim *GridConstructor* ein *SignalBus* genutzt. Der schematische Aufbau der Zelle ist in Abbildung 5-4 dargestellt.

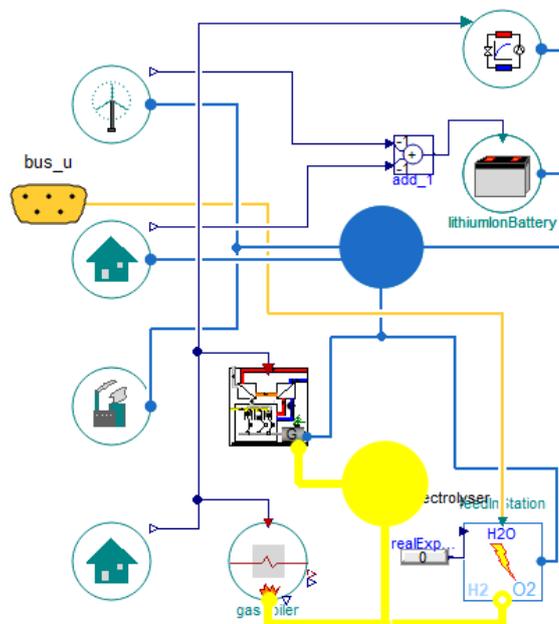


Abbildung 5-4: grafische Oberfläche des Modelica-Modells einer Hexagonzelle.

Für die modelltechnische Umsetzung des zellulären Ansatzes wurde eine Bibliothek „Gridelica“ in Python geschrieben, die Funktionen enthält, um die Daten der georeferenzierten Zellen in Modelica

zu übertragen und ein simulationsfähiges Modell zu erhalten. Der Name setzt sich aus „Grid“ und „Modelica“ zusammen und spielt darauf an, dass die Bibliothek für die Erstellung von Modellen mit Energienetzen Verwendung findet. Die Bibliothek ist darauf ausgelegt, dass als Grundlage für die Energiezellen die in 6.1.1. vorgestellten Hexagone verwendet werden. Das Energiezellenmodell benötigt einen Strom- und Gasport und kann davon abgesehen nach Bedarf gestaltet werden. Für den Netzaufbau müssen die Hexagone die Information beinhalten, über welchen Strom- bzw. Gasknotenpunkt sie an die höherliegende Netzebene angeschlossen sind, was über eine eindeutige ID geschieht. Diese Strom- und Gasknotenpunkte werden ebenfalls als Geodaten eingelesen.

Entsprechend diesem zu erstellenden Energiezellenmodell wurden die Klassen „Hexagon“, „EntryExit“ und „Connection“ definiert. Zur effizienten Verarbeitung werden die Geodaten in Objekte der entsprechenden Klassen umgewandelt, sodass für jede Klasse eine Liste vorliegt, in der jedes Element ein Instanzobjekt der entsprechenden Klasse ist. Dadurch werden die Geodaten passend strukturiert und die spezifischen Funktionen und Methoden der Klassen können zur Modellgenerierung verwendet werden. Die Hexagone als Zellen sind Objekte der Klasse „Hexagon“. Sie benötigen als Parameter eine ID zur eindeutigen Identifizierung, die Geometrieinformationen und für Strom und Gas über einen Boolean-Wert jeweils die Information, ob ein Anschluss an die entsprechenden Netze in der Zelle vorhanden ist. Die Instanzen der Klasse „EntryExit“ sind die Knotenpunkte der Gas- und Stromnetze. Ihre Parameter sind ein Name, der sich z.B. aus der Art des Knotenpunkts und der ID zusammensetzen lässt, die Angabe des Typs als „Strom“ oder „Gas“ und die Geometrieinformationen. Die Instanzen der Klasse „Connection“ benötigen als Parameter die beiden Modelle, die sie verbinden sollen und eine Angabe des Typs als „Strom“ oder „Gas“. Ein Objekt der Klasse „Connection“ wird für die Hexagone und Knotenpunkte erstellt, die laut den Geodaten miteinander verbunden sind.

Alle benötigten Last- und Erzeugungsprofile können den Hexagonen mit der Funktion „add_load_profiles“ hinzugefügt werden. Dafür wird jeweils eine CSV-Datei für jeden Erzeuger und Verbraucher, der ein Profil zugewiesen bekommen soll, eingelesen. In der Datei ist für jedes Hexagon ein Profil hinterlegt, identifizierbar durch eine eindeutige ID. Die Funktion iteriert durch die Hexagone, findet anhand der ID die zugehörige Spalte in den CSV-Dateien und fügt das Profil dem Hexagon hinzu. Anschließend speichert es die Profile in einem von Modelica lesbaren Format in einer neuen CSV-Datei. Weitere Parameter, wie die Kapazität vorhandener Batterien, können dem Hexagon über die Funktion „add_param“ hinzugefügt werden.

Mithilfe der Funktion „save_as_mo“ wird die MO-Datei aus den einzelnen Bestandteilen zusammengesetzt, sodass sie in Dymola geöffnet und nach ein paar wenigen zusätzlichen Anpassungen simuliert werden kann. Dafür wird für jedes Hexagon das Modelica-Hexagonmodell eingefügt und parametrisiert, ebenso die Knotenmodelle für Strom und Gas. Die Verbindungen zwischen Hexagon- und Knotenmodelle werden auf Textebene eingefügt, eine grafische Darstellung findet nicht statt. In Abbildung 5-5: ist beispielhaft die grafische Ebene eines so erstellten Modells dargestellt.

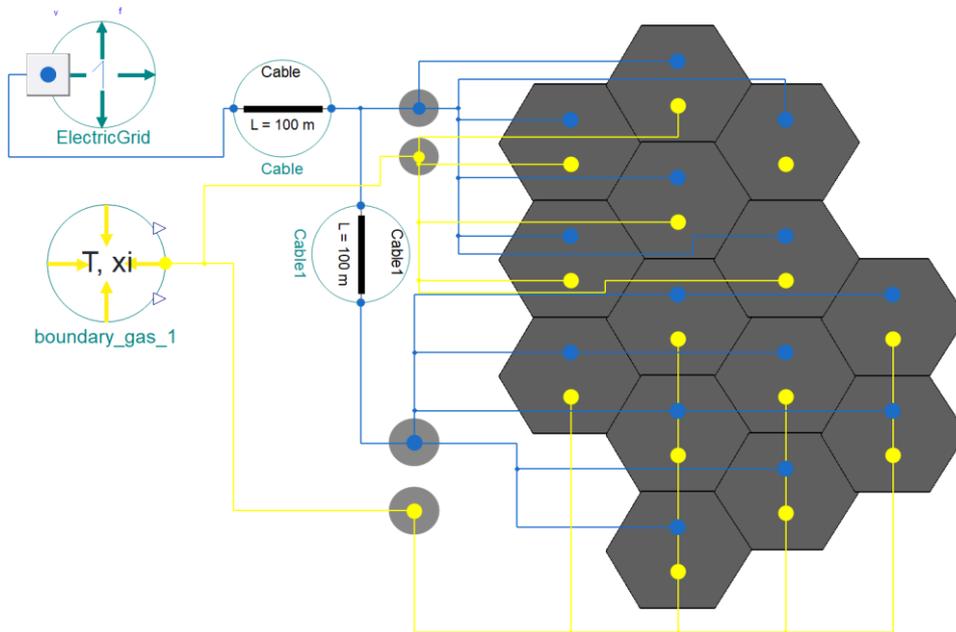


Abbildung 5-5: Beispielhafte Darstellung der grafischen Modellebene eines mit "Gridelica" erzeugten Modells mit zusätzlich eingefügten Kabeln und Boundaries.

Für die Regelung der Elektrolyseure werden zwei verschiedene Ansätze betrachtet, die unterschiedliche Ziele und Wissenshorizonte voraussetzen. Bei dem ersten Regelungsansatz wird als Regulationssignal die deutschlandweite Über- und Unterdeckung des Strombedarfs verwendet, die das Ergebnis der Erstellung der deutschlandweiten Merit-Order ist. Es wird davon ausgegangen, dass der Strom bei einer Überdeckung vergleichsweise günstig ist und es daher einen finanziellen Anreiz gibt, die Elektrolyseure zu diesen Zeiten zu betreiben. Folglich erhalten die Elektrolyseure, wenn die Überdeckung einen Schwellenwert, der abhängig von der Minimalleistung der Elektrolyseure ist, überschreitet, das Signal zur Wasserstoffproduktion, wobei die gesamte maximale Leistung durch die Höhe der Überdeckung begrenzt wird. Die zweite Regelungsstrategie verfolgt das Ziel, die Lastspitzen im Betrachtungsgebiet auszugleichen, weswegen analog die lokale Residuallast verwendet wird. Beide Regelungsstrategien werden in Modelica umgesetzt. Die Leistungswerte werden über den Control-Bus an die Elektrolyseure in den Zellen weitergeleitet.

Die genaue Beschreibung der simulierten Szenarien und die Darstellung der Ergebnisse finden sich in Kapitel 8.

6 Zellulärer Ansatz zur Technologiebewertung

Durch die wachsende Integration dezentraler Anlagen und dargebotsabhängiger Erzeuger steigt der Ausgleichsbedarf in den Netzen. Hierbei gewinnt auch der Ausgleich auf horizontaler Ebene zwischen benachbarten Regionen an Bedeutung. Zur genaueren Untersuchung dieser Ausgleichsströme werden die Regionen in abstrahierter Form als Energiezellen betrachtet.

Grundlegend für eine detaillierte Betrachtung ist eine genaue Abbildung der räumlich-energetischen Charakterisierung der einzelnen Zellen hinsichtlich Erzeugungs- und Verbrauchsdaten. Insbesondere ist auf der Erzeugerseite eine genaue Kenntnis über die installierten PV- und Windkraftanlagen notwendig. Nur durch eine möglichst realitätsnahe Abbildung des Ist-Zustandes ist eine realistische Abschätzung der räumlichen Entwicklung der Anlagen für die Zukunftsszenarien möglich. Dazu wurde eine Methode zur Lokalisierung von PV-Anlagen auf Luftaufnahmen entwickelt. Die methodischen Grundlagen zur Einteilung einer Region in Zellen sowie zur PV-Lokalisierung werden in Abschnitt 6.1 vorgestellt. Die Methodik zur Evaluierung des Ist-Zustands wird in Abschnitt 6.2 erläutert. Das Vorgehen zur Erzeugung der benötigten Bedarfsprofile findet sich in Abschnitt 6.4.

6.1 Grundlagen

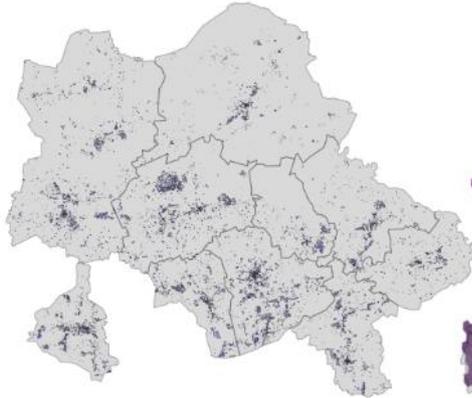
Zunächst wird in Abschnitt 6.1.1 die Basis für die Einteilung der Region in Zellen vorgestellt. Für die detaillierte Lokalisierung von existierenden kleinen PV-Anlagen wurden künstliche neuronale Netze auf hochaufgelösten Luftbildern trainiert. Die Grundlagen für das Modell werden in den weiteren Abschnitten dieses Kapitels behandelt.

6.1.1 Zellulärer Ansatz: H3-Hexagone

H3 ist ein hexagonales, hierarchisches Indexierungssystem, das von Uber als Open-Source-Paket bereitgestellt wird [30]. Die Funktionsweise von H3 beruht darauf, die Erdoberfläche in Hexagone verschiedener hierarchischer Level einzuteilen, um einzelne Datenpunkte zur besseren Weiterverarbeitung zusammenfassen zu können.

Dieses System ermöglicht die Generierung von Hexagonen in 16 verschiedenen Größen für jegliche Koordinaten oder Geometrien auf der Welt. Diese Hexagone dienen als Zellen zur Datenaggregation auf unterschiedlichen Ebenen. Die detaillierte Betrachtung der Sektorenkopplung im Rahmen des Projekts IntegraNet II wird anhand einer Beispielregion durchgeführt. Hierzu wurde die Region Münster ausgewählt. Genaueres zur Auswahl und Details zur Region sind in Abschnitt 6.3 zu finden. Für die betrachtete Region wird die Resolution 5 verwendet. Die Aggregation von Geoinformationen zu H3-Hexagonen erfolgt mithilfe der in H3 bereitgestellten Funktionen, die auf mathematischen statt auf räumlichen Beziehungen basieren. Dies ermöglicht eine effiziente und schnelle Verarbeitung von Geodaten.

GHD Gebäude in Münster



Auf H3 Hexagone aggregierte
Gebäudefläche

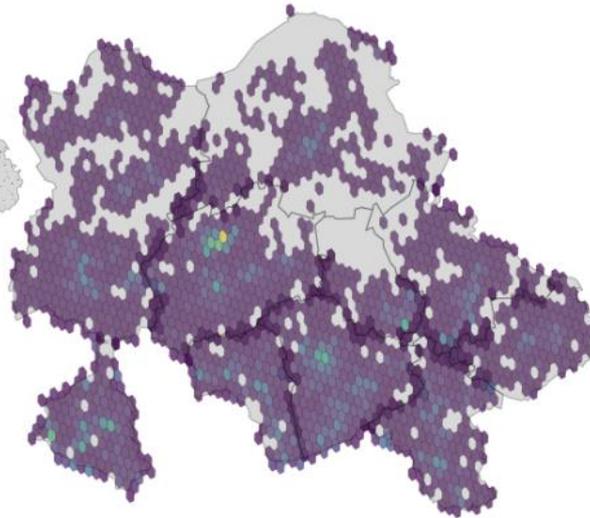


Abbildung 6-1: Aggregation der Fläche gewerblicher Gebäude in der Stadt Münster

Die Aggregation von Geoinformationen zu H3-Hexagonen erfolgt durch Zuordnen von geografischen Datenpunkten zu den entsprechenden Hexagonen auf der gewünschten Ebene. Dies geschieht anhand von mathematischen Berechnungen, die die geometrische Position des Punktes in Bezug auf die Hexagone berücksichtigen. So kann jedem betrachteten Datenpunkt, wie einzelnen Häusern, Wind- und PV-Anlagen oder Gasausspeisepunkten ein H3-Hexagon zugewiesen werden. Abbildung 6-1 zeigt diesen Vorgang exemplarisch an der Gebäudefläche aller Gebäude in Münster, die dem GHD-Sektor angehören. Abbildung 2-1

H3 ist besonders nützlich für Anwendungen, bei denen große Mengen von Geodaten effizient verarbeitet und analysiert werden müssen, wie zum Beispiel bei Geodatenanalysen. Die mathematische Natur des Systems ermöglicht es, komplexe geografische Analysen mit hoher Effizienz durchzuführen. Insgesamt bietet das H3-Indexierungssystem von Uber eine leistungsstarke Möglichkeit, Geoinformationen zu aggregieren und zu analysieren, wobei die Verwendung von Hexagonen auf hierarchischen Ebenen die Flexibilität und Effizienz bei der Verarbeitung von Geodaten erheblich verbessert.

6.1.2 Machine Learning

Das grundlegende Konzept des Maschine Learning (ML) besteht darin, dass ein Computer oder Algorithmus während des Betriebs bzw. der Ausführung dazu lernt. In der Praxis wird ein ML-Projekt oft in mehrere Phasen unterteilt, wobei eine Variante das CRISPDM-Modell ist, welches sechs Phasen umfasst [31].

Die erste Phase ist die Aufgabendefinition (engl.: business understanding), bei der die inhaltlichen Anforderungen in ein ML-Problem übersetzt werden. In der Anwendung der Methode im Rahmen von IntegraNet II (siehe Abschnitt 6.2) ist dies die semantische Segmentierung von Photovoltaik (PV) auf Luftbildern, um die Fläche der PV-Einheiten abschätzen zu können. Die zweite Phase ist das Datenverständnis (engl.: data understanding), bei dem die Qualität, Menge und Struktur der verfügbaren Daten analysiert werden. Dies ist entscheidend, um die Eignung der Daten für das ML-Projekt zu bewerten. Die dritte Phase, die Datenaufbereitung (engl.: data preparation), beinhaltet die Aufbereitung der Daten in einer geeigneten Form für den Algorithmus. Dazu gehört das Entfernen von Ausreißern, die Datennormierung und die künstliche Erweiterung des Datensatzes (engl.: data augmentation). In der Modellierungsphase (engl.: modeling) wird das eigentliche ML-Modell

trainiert, wobei die lernbaren Parameter des Modells optimiert werden. Hier erfolgt auch die Auswahl eines geeigneten Modells. Die Evaluierungsphase (engl.: evaluation) dient dazu, die Erfüllung der Anforderungen an das Modell zu überprüfen. Hierbei wird das Modell mit neuen, ungesehenen Daten validiert. Schließlich erfolgt die Umsetzungsphase (engl.: deployment), bei der das trainierte Modell auf neue, unbekannte Daten bzw. auf den Anwendungsfall, für den es entwickelt wurde, angewendet wird.

Um die Leistung des Modells während der Umsetzungsphase sicherzustellen, wird der Datensatz nach der Datenverarbeitung zufällig in Trainingsdaten und Testdaten aufgeteilt. Zusätzlich kann eine Validierungsmenge eingeführt werden, die von der Trainingsmenge abgetrennt wird. Das Modell wird auf der verbleibenden Trainingsmenge trainiert und anschließend auf der Validierungsmenge getestet, um festzustellen, wie gut es generalisiert. Dies ermöglicht eine frühzeitige Überprüfung der Modellleistung während der Modellierungsphase.

Overfitting und Underfitting

Zwei mögliche Gründe, weshalb ein Modell nicht gut generalisiert, sind das sogenannte Overfitting und Underfitting. Ein Kennzeichen für Underfitting ist ein zu hoher Fehler auf dem Trainingsdatensatz. Mögliche Ursachen hierfür können zu wenige Daten, ein nicht austrainiertes oder ein nicht ausreichend komplexes Modell sein. Overfitting liegt dann vor, wenn die Trainingsfehler zwar gering sind, der Fehler auf dem Testdatensatz jedoch hoch. Das Modell hat sich in dem Fall den Trainingsdaten zu sehr angepasst, wodurch eine schlechte Generalisierung stattfindet. Das kann z.B. durch ein zu langes Training oder durch zu komplexe Modelle, die Merkmale aus dem Trainingsdatensatz verarbeiten, die im Testdatensatz nicht existieren, hervorgerufen werden. Die Kapazität des Modells (Vielfalt an Funktionen, die es nachahmen kann) kann aussagen, ob ein Modell zu Overfitting oder Underfitting tendiert. Modelle mit einer niedrigen Kapazität neigen zu Underfitting, während Modelle mit einer hohen Kapazität zu Overfitting neigen.

Datenqualität

Die Güte der Generalisierung des Modells ist nicht nur von dem Modell selbst abhängig, sondern auch von den Daten, mit denen das Modell trainiert wird. So müssen genügend und saubere Daten erzeugt werden können. Sind ausreichend Daten vorhanden, kommen nach [32] Algorithmen mit unterschiedlicher Komplexität zu fast identischen Ergebnissen. Da die Menge der Daten in der Praxis allerdings meist begrenzt ist, hat hier die Wahl des Modells einen entsprechend größeren Einfluss.

Neben der Menge ist auch die Qualität der Daten ein entscheidender Einflussfaktor auf die Güte der Ergebnisse. Ist der Trainingsdatensatz fehlerbehaftet, so wird das Modell diese Fehler mit übernehmen, z.B. falsche Kennzeichnung von Flächen. Der Trainingsdaten müssen zudem repräsentativ für den Anwendungsfall sein. Beispielsweise darf ein Datensatz nicht aus ausschließlich Bildern von PV-Anlagen im industriellen Maßstab bestehen, wenn auch PV-Anlagen auf Dächern von Wohnhäusern erkannt werden sollen.

6.1.3 Neuronale Netze

Um die PV-Anlagen auf Luftbildern erkennen zu können, wird mit einer speziellen Form von ML-Algorithmen gearbeitet. Dabei handelt es sich um die so genannten künstlichen neuronalen Netze (KNN). Diese sollen wie in einem Gehirn miteinander vernetzt werden, um komplexe Aufgaben zu lösen. Neuronen erhalten dabei Eingangssignale von weiteren Neuronen oder Sensoren und verarbeiten diese, um anschließend ab einem bestimmten Schwellwert einen Impuls zu weiteren Neuronen abzugeben [33]. Signale werden lediglich in eine Richtung weitergeleitet. Folgende Formel stellt dieses Verhalten mathematisch dar [33]:

$$f(x) = G(wx^T + b)$$

Dabei ist $w \in \mathbb{R}^d$ der Gewichtsvektor, $x \in \mathbb{R}^d$ der Eingangsvektor und $b \in \mathbb{R}$ der Bias. G ist die Funktion, die den Schwellwert bestimmt, ab dem das Neuron einen Impuls abgibt. Ein künstliches Neuron berechnet die gewichtete Summe der Eingänge und wendet anschließend eine Aktivierungsfunktion an, um den Ausgangswert zu bestimmen. Ein Neuron kann bildlich gesprochen als ein Knoten im Graphen gesehen werden. Ein KNN besteht aus vielen, in Schichten miteinander vernetzten Neuronen.

Feedforward Neural Networks

Eine große Gruppe von neuronalen Netzen bilden die Feedforward Neural Networks (FNN). Diese sind dadurch charakterisiert, dass die Verbindungen zwischen den Neuronen keine Schleifen bilden [34]. Das Ziel eines FNNs ist die Approximation der Funktion f^* . Das FNN definiert eine Abbildung $f(x, \theta)$ und lernt die besten Parameter θ , darunter die Bias-Terme und Gewichte der Neuronenverbindungen. Eine Trainingsepisode, in der alle Daten einmal verwendet werden, heißt Epoche.

FNNs bestehen aus verschiedenen hintereinandergeschalteten Funktionen (auch Schichten oder Layer genannt) [34]. Sie bestehen aus Input Layer (abhängig von den Eingabewerten), Hidden Layer (in denen die meisten Berechnungen stattfinden) und Output Layer (der den Ausgabewert berechnet). Die Anzahl der Schichten wird als Tiefe und die Anzahl der Neuronen in einem Layer als Breite bezeichnet.

Das FNN umfasst Input Layer $I \in \mathbb{R}^d$, zwei Hidden Layer $H_1 \in \mathbb{R}^{d_1}$ und $H_2 \in \mathbb{R}^{d_2}$ sowie Output Layer $Z \in \mathbb{R}^{d_z}$. Jedes Neuron ist mit den Neuronen aus dem vorherigen Layer verbunden (fully connected), was beispielsweise bedeutet, dass es $d_1 * d_2$ Verbindungen zwischen H_1 und H_2 gibt. Die Verbindungen von I zu H_1 sind mit W_1 gekennzeichnet, wobei $W^1(i, j) = w_{i,j}^1$ die Verbindung vom i -ten Input zum j -ten Neuron in H_1 ist. Die linearen Berechnungen werden als $a^{(l)}$ bezeichnet, und die Vorhersage \hat{y} erfolgt wie folgt durch Forward Propagation:

$$\begin{aligned} f_1 &= G(xW^{(1)} + b^{(1)}) = h^{(1)} \\ f_2 &= G(h^{(1)}W^{(2)} + b^{(2)}) = h^{(2)} \\ f_3 &= G(h^{(2)}W^{(3)} + b^{(3)}) = h^{(3)} \\ f(x) &= G(G(G(a^{(1)})a^{(2)})a^{(3)}) = \hat{y} \end{aligned}$$

Diese Berechnung umfasst auch die Anwendung der Aktivierungsfunktion G und besteht hauptsächlich aus Matrix-Vektor-Multiplikationen und Vektor-Vektor-Additionen. FNNs können gemäß dem Universal Approximation Theorem jede stetige Funktion mit nur einem Hidden Layer und endlich vielen Neuronen approximieren. [33]

Aktivierungsfunktion

Die Aktivierungsfunktion bestimmt, wie die Ausgabewerte der Neuronen aus den Eingabewerten berechnet werden. In der Praxis verwenden Neuronen in einer Schicht dieselbe Aktivierungsfunktion. Lineare Funktionen sind in FFNs ungünstig, da sie keine Nichtlinearitäten approximieren können. Die Aktivierungsfunktion sollte außerdem differenzierbar sein, um Gradienten für die Optimierung nutzen zu können. Zwei wichtige Aktivierungsfunktionen sind die Sigmoid Funktion und ReLU (Rectified Linear Unit). Erstere ist stetig, nicht-linear und differenzierbar. Für größere Werte von $|a|$ flacht die Funktion sehr stark ab, was bedeutet, dass die Gradienten gegen 0 gehen. Dies kann zum Problem der verschwindenden Gradienten führen. Die ReLU ist eine Standardwahl für die Aktivierungsfunktion für FNNs [34]. Sie ist stetig und nicht linear. Allerdings ist sie an der Stelle $x = 0$ nicht differenzierbar. Der große Vorteil ist, dass die Ableitung auf \mathbb{R}^+ stets gleich 1 ist und somit das Problem des verschwindenden Gradienten vermeidet [33].

Loss-Function und Backpropagation

Die Loss Function (Kostenfunktion/Verlustfunktion) soll durch das Anpassen ihrer Parameter optimiert werden. Beispiele für Loss-Functions sind die Binary-Cross-Entropy (Kreuzentropie)-Methode und die Dice-Loss-Funktion.

Backpropagation ist ein Verfahren, um die Gradienten zur Optimierung der Loss-Function zu bestimmen und so den Einfluss jedes Parameters auf die Loss-Function zu quantifizieren. Diese Gradienten werden dann verwendet, um die Gewichte mithilfe eines gradientenbasierten Optimierungsverfahrens anzupassen. Normalerweise könnten die Gradienten mithilfe der Kettenregel berechnet werden, jedoch kann dies sehr rechenaufwendig sein, insbesondere für große neuronale Netze mit Tausenden oder Millionen von Neuronen. Mit dem Backpropagation-Algorithmus können die Gradienten effizienter berechnet werden. Durch eine optimierte Anwendung der Kettenregel sollen mit dem Algorithmus doppelte Berechnungen vermieden werden. Der Algorithmus beginnt damit, dass ein Trainingsbeispiel mit Eingabewert x und Label y durch das Netz geht und der Verlust L der Ausgabe \hat{y} berechnet wird (Forward-Propagation). Dabei werden die Ergebnisse der Matrix-Vektor-Berechnungen $a^{(k)}$ und die Ausgaben der Aktivierungsfunktionen $h^{(k)}$ sowie der Verlust J gespeichert, um sie später für die Backpropagation zu verwenden. Im nächsten Schritt wird der Backpropagation-Algorithmus gestartet. Dieser berechnet die Gradienten g der gespeicherten Aktivierungen $a^{(k)}$ rückwärts von der letzten Schicht zur ersten Schicht mithilfe der Kettenregel. Mit diesen Gradienten g werden dann die Gradienten der Gewichte und Bias-Terme berechnet, die wiederum zur Optimierung des Netzwerks verwendet werden.

Optimierer und Learning Rate

Das eigentliche Lernen des Neuronalen Netzes wird durch die Optimierungs-Algorithmen bestimmt. Ziel der Optimierung ist es, die Kostenfunktion zu minimieren.

Das **Gradienten-Verfahren** ist ein generisches Optimierungsverfahren, auf dem andere Methoden aufbauen. Ausgehend von Initialwerten, wird in jedem Schritt der Gradient berechnet. Zur Minimierung werden die Parameter entlang des negativen Gradienten verschoben. Dazu müssen in jeder Iteration die Gradienten für alle Trainingsdaten berechnet werden, was rechenaufwendig ist und den Speicherbedarf erhöht. Dies begrenzt die Trainingsdatenmenge. Verfahren, die die Gradienten anhand der gesamten Trainingsdaten bestimmen, werden Batch-Gradienten-Verfahren genannt. [34]

Das **Stochastische Gradienten-Verfahren** (SGD) ist ein häufig verwendetes Optimierungsverfahren, das im Wesentlichen dem Batch-Gradienten-Verfahren ähnelt, jedoch den Gradienten nur auf einer zufälligen Teilmenge der Trainingsdaten berechnet (Batch-Size, typischerweise eine Zweierpotenz zwischen 32 und 256). Dies beschleunigt die Berechnungen und ermöglicht das Training mit großen Datensätzen.

Die Learning Rate bzw. Schrittweite α ist ein entscheidender Hyperparameter für die Optimierung. Eine zu große Schrittweite kann dazu führen, dass das Problem nicht konvergiert, während eine zu kleine Schrittweite den Algorithmus verlangsamt. [35]

Die Learning Rate kann als konstanter Wert gesetzt werden, oder abhängig von der Epoche variiert werden (z.B. kleiner werdende Werte mit steigender Anzahl an Epochen). Die Wahl der richtigen Learning Rate ist keine exakte Wissenschaft und basiert oft auf dem Try-and-Error Prinzip. Adaptive Lernraten-Algorithmen bieten eine Möglichkeit zur Vereinfachung dieses Prozesses. [34]

Der **Adam-Optimierer** [36] ist ein solcher gradienten-basierter Optimierungs-Algorithmus mit adaptiver Learning Rate. Jedem Parameter wird eine individuelle Learning Rate zugewiesen und eigenständig angepasst. Adam steht dabei für „adaptive momentum“. Er nutzt sowohl Informationen

aus vorherigen Gradienten (first order moment), als auch Informationen aus dem Quadrat der vorherigen Gradienten (second order moment).

Metriken

Am Ende des Trainings liefert jedes Modell ein Ergebnis, was aber nicht unbedingt das beste mögliche Ergebnis für die jeweilige Problemstellung sein muss. Mit der Loss-Funktion lässt sich die Performance eines Modells bewerten. Allerdings lassen sich damit Modelle mit unterschiedlichen Verlustfunktionen nicht gut vergleichen. [31]

Um Modelle untereinander zu vergleichen, werden verschiedene Metriken verwendet. Die im Rahmen des Projektes verwendeten Metriken werden im Folgenden kurz vorgestellt.

Die **Accuracy** (Genauigkeit) [33] ist ein Maß für die Klassifizierung. Es gibt das Verhältnis der richtig klassifizierten Bilder zur Gesamtmenge an. Diese Metrik hat jedoch den Nachteil, dass sie bei ungleich verteilten Klassen nicht aussagekräftig ist. Wenn beispielsweise 90 % der Datenbilder ohne PV und nur 10 % mit PV sind, kann ein Modell, das alle Bilder als "ohne PV" klassifiziert, eine Accuracy von 90 % erreichen, obwohl diese Vorhersage sehr schlecht ist.

Die **Precision** [35] gibt das Verhältnis zwischen den richtig positiv klassifizierten Bildern und allen als positiv klassifizierten Bildern an, inklusive den falsch positiv klassifizierten.

Der **Recall** oder auch die **Sensitivity** gibt das Verhältnis der richtig positiv klassifizierten Bilder zu allen positiven Bildern (also in unserem Beispiel zu allen Bildern mit PV) an. Precision und Recall sollten nicht isoliert betrachtet werden, um die Modelleistung zu beurteilen. Ein hoher Precision-Wert allein kann z.B. auch dadurch entstehen, dass sehr wenige Bilder als positiv klassifiziert werden, es also viele falsch negative Klassifizierungen gibt. Ohne den zugehörigen Recall-Wert ist die Bewertung daher nicht aussagekräftig. [35]

Der **Intersection over Union (IoU) Score** oder **Jaccard Score** ist ein Maß, das häufig für die semantische Segmentierung genutzt wird. Es wird über das Verhältnis der richtig positiv klassifizierten Bilder zu der Summe aus den richtig positiv, den falsch positiv und den falsch negativ bestimmten Bildern berechnet. Dieses Maß gibt einen Wert aus dem Intervall $[0,1]$ aus, wobei 0 dem schlechtesten und 1 dem besten Ergebnis entspricht. Der **Dice Score** (ebenfalls F1 Score) ist dem IoU Score sehr ähnlich, wobei die richtig positive Klassifizierung doppelt gewichtet wird. [31]

Desweiteren gibt es Metriken, bei denen die explizit vorhergesagte Fläche (hier der PV-Anlagen) mit der wahren Fläche verglichen wird. [37]

Mit dem **Mean Absolute Error (MAE)** wird der mittlere, absolute Fehler von der Größe der vorhergesagten PV-Anlage zur Größe der echten PV-Anlage bestimmt.

Der **Normalized Mean Absolute Error (NMAE)** normiert im Gegensatz zum MAE nicht mit der Anzahl der Anlagen/Flächen, sondern mit der wahren Gesamtfläche.

Beim **Bias Wert** wird nicht die Summe des Betrags der Fehler bestimmt, sondern die Summe der Fehler ohne Bildung des Betrags, also unter Berücksichtigung des Vorzeichens, gebildet. Dadurch gibt er an, um wie viel der wahre Wert im Mittel über- oder unterschätzt wird.

Der **Mean Absolute Percentage Error (MAPE)** gibt den mittleren absoluten prozentualen Fehler aller vorhergesagten Flächen an.

Regularisierung

Regularisierung ist ein Oberbegriff für alle Methoden, die den Testfehler und nicht den Trainingsfehler verringern sollen, ergo Overfitting minimieren sollen [34].

Die **Dropout**-Methode ist ein weit verbreitetes Regularisierungsverfahren. Sie führt einen Hyperparameter, die Dropout-Rate ($p \in [0,1]$), ein. In jedem Schritt während des Trainings haben

Neuronen (außer den Ausgangsneuronen) eine Wahrscheinlichkeit von p , gedroppt zu werden. Gedropte Neuronen verlieren vorübergehend ihre Verbindungen und werden ignoriert. Nach dem Training für das Testen werden wieder alle Neuronen genutzt. Obwohl die Methode den Algorithmus verlangsamen kann, führt sie in der Regel zu deutlich besseren Ergebnissen und ist eine effektive Maßnahme gegen Overfitting. [35]

Die **Early Stopping** Methode basiert darauf, dass beim Overfitting der Trainingsfehler während des Trainings kontinuierlich abnimmt, während der Validierungsfehler nach einer bestimmten Zeit wieder ansteigt. Ziel ist es, den Zeitpunkt mit dem minimalen Validierungsfehler zu speichern und das Training abzubrechen, wenn in den nächsten Epochen keine Verbesserung des Validierungsfehlers erfolgt. Der Hyperparameter s legt fest, nach wie vielen Epochen der Algorithmus vorzeitig abgebrochen wird, wenn keine Verbesserung im Validierungsfehler zu erkennen ist. In bestimmten Fällen, in denen der Validierungsfehler ansteigt, aber Metriken wie der Validierungs-Dice-Koeffizient weiterhin steigen, sollte das Training nicht vorzeitig beendet werden. [33], [34]

Eine weitere Methode, um Overfitting zu vermeiden, wäre das Training auf einer größeren Datenmenge. Da jedoch oft nur begrenzte Daten zur Verfügung stehen, kann die Methode **Data Augmentation** verwendet werden, um die vorhandenen Daten künstlich zu erweitern. Die Anwendbarkeit dieser Methode hängt von der spezifischen Problemstellung und den Daten ab und erfordert ein detailliertes Verständnis der Daten. [34]

Die **Batch-Normalization** ist eine Methode, die in der Data Preparation Phase angewendet wird, um zwischen den Layern innerhalb des neuronalen Netzes die Inputs zu normalisieren und zu standardisieren. Dazu wird eine Operation vor oder nach der Aktivierungsfunktion eines Hidden Layers eingeführt, die die Inputs zunächst nullzentriert, normalisiert und dann skaliert und verschiebt. Diese Operation hat lernbare Parameter für Skalierung und Verschiebung. Die Schätzung der Mittelwerte und Standardabweichungen erfolgt anhand der Inputs eines Minibatches. Durch die Batch-Normalization können die Trainingsgeschwindigkeit und Lernraten verbessert werden. [35]

Um Batch-Normalization auch nach dem Training anzuwenden, werden während des Trainings globale Werte für Skalierung und Verschiebung berechnet, die nur für die Anwendung, nicht aber während des Trainings selbst verwendet werden.

6.1.4 Semantische Segmentierung und Convolutional Neural Networks

Um die Flächen der PV-Anlagen auf Dächern zu identifizieren, kommen Methoden der digitalen Bildverarbeitung zum Einsatz. Bei der semantischen Segmentierung wird im Gegensatz zur einfachen Klassifizierung, bei der ein gesamtes Bild einem Label zugeordnet wird, die Klassifizierung jedes Pixels einzeln vorgenommen. Alle Pixel, die zu Photovoltaikanlagen gehören, können einer Klasse zugeordnet werden, während die Hintergrundpixel eine andere Klasse bilden. Durch die Zusammenführung dieser PV-Pixel kann dann die Fläche der Photovoltaikanlagen bestimmt werden. Dies kann mithilfe von Convolutional Neural Networks (CNNs) erreicht werden, die speziell für die Verarbeitung von Bilddaten entwickelt wurden.

Im Gegensatz zu FNN, die zur Bildverarbeitung für kleine Bilder genutzt werden, können Convolutional Neural Networks (CNNs) den Rechenaufwand auch für große Bilddatenmengen lösen. Durch das Teilen der Parameter (engl.: parameter sharing) wird die Anzahl der Parameter reduziert. Zudem werden die Neuronen nicht vollständig miteinander verbunden (engl.: partial connections), um die Anzahl der Verbindungen geringer zu halten. Die Layer in CNNs heißen Convolutional Layer.

Convolutional Layer

In einem Convolutional Layer sind die einzelnen Neuronen einer Schicht nicht mit allen Neuronen aus der vorherigen Schicht verbunden, sondern nur mit denen in einem begrenzten Bereich, dem sogenannten rezeptiven Feld (engl.: receptive field). Der erste Layer in dieser Architektur erfasst

einfache Merkmale, die in den folgenden Layern zu immer komplexeren Merkmalen zusammengesetzt werden. Ein Neuron in Zeile i und Spalte j ist mit den Neuronen in den Zeilen $[i; i + f_h - 1]$ und den Spalten $[j; j + f_w - 1]$ aus dem vorherigen Layer verbunden, wobei f_h die Höhe und f_w die Breite des rezeptiven Feldes ist. Um Layer gleicher Größe zu verbinden, können Nullen um das Bild herum hinzugefügt werden, was als "Zero Padding" bekannt ist. Die Verschiebung des rezeptiven Feldes wird als stride bezeichnet. [35]

Der Filter des CNN wird auf alle Neuronen in einem Layer angewendet und der Output wird als Feature Map bezeichnet. Als Filter oder Kernel werden die Gewichte im CNN bezeichnet. Der Filter ist ein Bild oder Tensor, der die Größe des rezeptiven Feldes hat. Die Feature Map ist in der Regel 2-dimensional und zeigt, welche Bereiche im Bild den Filter am meisten aktivieren. Ein CNN kann so ein gelerntes Muster an verschiedenen Stellen im Bild erkennen. Ein FNN kann im Gegensatz dazu ein Muster nur an der gleichen Stelle erkennen, an dem es gelernt wurde. Innerhalb der Feature Map kommt das parameter sharing zum Tragen. Dort teilen alle Neuronen in einer Feature Map dieselben Parameter, was die Anzahl der Parameter erheblich reduziert. Während des Trainings lernt das CNN die wichtigsten Filter automatisch. Bilder mit RGB-Farbcodes haben für jede Farbe einen eigenen Kanal, also insgesamt drei Kanäle (rot, grün und blau). Ein Filter mit der Größe $a \times a$ entspricht dann für ein Farbbild einem Tensor von $a \times a \times 3$ mit $a \times a \times 3$ Gewichten. [34], [35]

Ein CNN besteht im Allgemeinen aus mehreren Convolutional Layern, gefolgt von einem Pooling Layer und ähnlichen Schichten. Oft wird am Ende des CNNs noch ein kleines FNN hinzugefügt. Die Anordnung der Schichten in einem CNN kann variieren und hat einen erheblichen Einfluss auf das Verhalten des Modells [35]. Zu bekannten Modellen gehören das VGG16 [38], VGG19 und das DenseNet121 [39].

Pooling Layer

Pooling Layer in CNNs dienen dazu, das Bild zu verkleinern, die Parameteranzahl zu reduzieren und den Rechenaufwand zu verringern, was tiefere Netze ermöglicht. Wie in Convolutional Layern sind Neuronen nicht mit allen Neuronen aus der vorherigen Schicht verbunden. Pooling Layer haben keine Gewichte, sondern definieren lediglich, wie Pixel zusammengefasst werden. Die gebräuchlichste Methode ist Max-Pooling, bei der nur der höchste Wert im rezeptiven Feld weitergegeben wird. Das Max-Pooling wird für jeden Kanal eines Inputs einzeln angewandt, und der Output des Max-Pooling Layers hat die gleiche Anzahl an Kanälen wie der Input. Dies führt zu einer Invarianz gegenüber kleinen Translationen im Bild und es gehen Informationen verloren. [35]

Transfer Learning

Transfer Learning ist ein Ansatz, bei dem Informationen aus einem bereits trainierten neuronalen Netzwerk auf ein ähnliches Problem angewendet werden, um die Trainingszeit zu verkürzen und weniger Daten für gute Ergebnisse zu benötigen. Dies funktioniert besonders gut bei CNNs. Bei diesem Ansatz werden einige Schichten des vorherigen Netzwerks eingefroren, während andere weiterhin trainiert werden. Dies ermöglicht die Wiederverwendung von Features, die in den ersten Schichten niedriger Ebene enthalten sind und oft für verschiedene Anwendungen ähnlich sind. Später können beim sogenannten Fine Tuning die eingefrorenen Schichten wieder trainierbar gemacht werden, um spezifischere Merkmale für die neue Aufgabe zu erlernen. [35]

Transpose Convolutional Layer

Wie oben beschrieben, unterscheidet sich die semantische Segmentierung dadurch von der klassischen Bildverarbeitung, dass jedes Pixel in einem Bild individuell klassifiziert wird. Zwischen Objekten derselben Klasse wird dabei nicht unterschieden. Um jedes Pixel genau zu klassifizieren, muss der Output erneut ein Bild derselben Größe sein. Durch Max-Pooling-Layer und größere Schrittweiten (strides) werden die Bilder verkleinert, was dazu führt, dass nur die ungefähre Position

von beispielsweise PV-Anlagen erkannt werden kann, aber nicht die genauen Pixel. Um dieses Problem zu lösen und die Bildgröße wiederherzustellen, können sogenannte Transpose Convolutional Layer verwendet werden.

Die Transpose Convolutional Layer sind ähnlich wie Convolutional Layer oder Pooling Layer aufgebaut, jedoch erzeugen sie größere Feature Maps im Vergleich zu ihrem Input, indem sie Nullen zwischen den Pixeln eines Bildes hinzufügen und es dadurch vergrößern. Diese Layer können durch die Anpassung des strides gesteuert werden, der angibt, wie viele Reihen und Spalten von Nullen zwischen den Pixeln eingefügt oder wie weit die Pixel voneinander entfernt sein sollen. Ein größerer stride führt zu einem größeren Output. Mit Convolutional Layer, Transpose Convolutional Layer und Pooling Layer können Architekturen für die semantische Segmentierung erstellt werden. Solche Architekturen verkleinern zunächst ein Bild und vergrößern es dann wieder, ähnlich wie Autoencoder. Es gibt viele verschiedene Architekturen für die semantische Segmentierung, die aktiv in der Forschung weiterentwickelt werden. [35]

Unet

Unet ist eine spezielle Architektur von Convolutional Neural Networks (CNNs), die ursprünglich für die biomedizinische Segmentierung entwickelt wurde. Es zeichnet sich durch seine Effizienz und die Fähigkeit aus, auch mit begrenzten Datenmengen gute Ergebnisse zu erzielen [40]. Der Name kommt von der U-förmigen Architektur, die aus einem Encoder (downsampling), einer Bridge (Übergang) und einem Decoder (upsampling) besteht. Der Encoder enthält mehrere Schichten von Convolutional Layern mit ReLU-Aktivierungsfunktion und Max-Pooling-Layern. Der Max-Pooling-Layer reduziert die Bildgröße. Der Decoder besteht aus Transpose Convolutional Layern, die die Feature Maps vergrößern, gefolgt von Convolutional Layern, um die verlorenen Informationen beim Downsampling zu kompensieren. Am Ende wird ein Bild mit derselben Größe wie das Eingangsbild generiert, wobei jedes Pixel die Wahrscheinlichkeit angibt, zur jeweiligen Klasse zu gehören. Das Unet-Modell hat sich in verschiedenen Anwendungen bewährt und wurde auch bereits bei der Segmentierung von Photovoltaikanlagen eingesetzt. [41]

Unet++

Unet++ ist eine Weiterentwicklung der Unet-Architektur, die 2018 für den medizinischen Bereich entwickelt wurde, um die Genauigkeit zu verbessern. In Unet++ wurden im Vergleich zu Unet die Verbindungen zwischen dem Encoder und Decoder angepasst. Dabei wurden Dense Blocks und Convolutional Layer eingeführt. Darüber hinaus wurde Deep Supervision eingeführt. Dies ermöglicht das Modell in zwei Arten zu verwenden: entweder mit Fokus auf Genauigkeit, indem die Outputs der Segmentation Branches gemittelt werden oder mit Fokus auf Geschwindigkeit, indem nicht alle Branches ausgewählt werden. [42]

6.2 Semantische Segmentierung von PV-Anlagen

Im folgenden Abschnitt wird die Anwendung der semantischen Segmentierung zur Bestimmung der PV-Anlagen in Deutschland beschrieben.

Anhand des Marktstammdatenregister ist eine Lokalisierung der ca. 2 Millionen registrierten PV-Anlagen nur per Postleitzahl möglich, ausgenommen große PV-Anlagen. Somit können die Anlagen anhand des Registers nicht in höherer Auflösung den Hexagonen zugeordnet werden. Um eine höhere geografische Auflösung zu erreichen, sollen die realen Anlagen mittels semantischer Segmentierung erkannt werden.

6.2.1 Datenvorbereitung

Grundlage für das Machine Learning-Modell zur Erkennung der PV-Anlagen bilden zwei unterschiedliche Datenquellen: ein Datensatz aus Kalifornien [43] und Daten des Bundesamts für Kartographie und Geodäsie [44] mit Luftaufnahmen aus Deutschland. Durch die unterschiedlichen Datenquellen erhöht sich die Diversität der Bilder, wodurch ein positiver Effekt auf die Robustheit des Modells erreicht werden soll.

Bei allen Bildern handelt es sich um Orthofotos, die bei Überflügen aufgenommen und so nachbearbeitet werden, dass die Perspektive orthogonal zur abgebildeten Fläche ist. Zudem sind sie georeferenziert, eingenordet und verzerrungsfrei und haben eine etwas bessere Auflösung als verfügbare Satellitenbilder. Ein Nachteil der Bilder ist die große zeitliche Varianz der Aufnahmen – zwischen den Aufnahmedaten der Bilder verschiedener Regionen können mehrere Jahre liegen. Dies kann den tatsächlichen Stand des PV-Ausbaus, der durch das auf diese Daten trainierte Modell bestimmt wird, etwas verfälschen.

Im Folgenden wird bei den Bildern zwischen Positiven (Bildern mit PV-Anlagen) und Negativen (Bildern ohne PV-Anlagen) unterschieden.

Der Datensatz aus Kalifornien stammt aus einer Arbeit, die sich auch mit der Identifikation von PV-Anlagen befasst [43]. Er umfasst 601 Bilder, mit fertig gelabelten PV-Anlagen (um alle PV-Flächen wurden Polygone gelegt). Jedes Bild hat eine Auflösung von 5 000 x 5 000 Pixeln und eine Auflösung von 30 cm pro Pixel. Insgesamt sind mehr als 19 000 PV-Anlagen enthalten.

Aus der zweiten Datenquelle, den Bildern des Bundesamts für Kartographie und Geodäsie wurden am GWI zwei weitere Datensätze als Input für das ML-Modell generiert. Die unbearbeiteten Bilder aus [44] haben eine Größe von 500 x 500 Pixeln und eine Auflösung von 20 cm.

Für den ersten Datensatz wurden auf 1 291 Bildern über 4 000 PV-Flächen händisch mit dem Programm „Labelme“ [45] mit Polygonen markiert. Die gewählten Bilder enthalten sowohl Freiflächen- als auch Aufdach-Anlagen in Gebieten mit unterschiedlicher Siedungsstruktur und -dichte (wie z.B. ländliche, oder städtische Regionen).

Bei der Anwendung der Modelle auf den Kalifornien- und den ersten GWI-Datensatz wurden viele Pixel falsch positiv segmentiert. Bei der Auswertung dieser falsch zugeordneten Pixel, konnten die Fehler vor allem auf Strukturen aus den folgenden Kategorien zurückgeführt werden:

- Glasoberflächen (z.B. Wintergärten, Glasdächer oder Gewächshäuser)
- Dachkonstruktionen (wie Dachfenster, oder besondere Dachformen)
- Autos/Parkraum (z.B. dicht geparkte Autos oder Parkplätze)
- Landwirtschaftliche Flächen (z.B. Felder)
- Einige industrielle Strukturen (z.B. Container)
- Schienen



Abbildung 6-2: Beispielbilder für die Kategorien Autos/Parkplätze und Glasoberflächen [44]

Um der falsch positiven Segmentierung entgegenzuwirken, wird daher ein weiterer Datensatz anhand der Bilder des Bundesamts für Kartographie und Geodäsie erzeugt. Hierbei wurden 175 Bilder (500 x 500 Pixel) ohne PV-Anlagen ausgewählt, zwei Beispiele sind in Abbildung 6-2 dargestellt.

Preprocessing

Bei allen drei Datensätzen wurden die Bilder auf mehrere Einzelbilder der Größe 250 x 250 Pixel zerschnitten. Für den Kalifornien-Datensatz ergaben sich dementsprechend pro 5 000 x 5 000 Pixel-Bild 400 kleinere Bilder. Beim GWI-Datensatz wurde zusätzlich ein Bild aus der Mitte erzeugt, sodass dort pro Bild fünf Bilder der Größe 250 x 250 Pixel erzeugt wurden.

Durch das Zerschneiden entstanden deutlich mehr Negative als Positive, daher wurden einige Negative aussortiert, so dass das Verhältnis zwischen Negativen und Positiven etwa 50/50 war. Zudem wurden alle Bilder mit weniger als 100 Pixeln PV-Fläche aussortiert.

Anschließend wurden die Datensätze mittels Data Augmentation erweitert. Hierzu wurden die Bilder an der Vertikalen gespiegelt und die Anzahl der Bilder somit verdoppelt. Die Bilder wurden nicht an der Horizontalen gespiegelt und nicht rotiert. Da PV-Anlagen in der Regel nicht nach Norden ausgerichtet werden, hätte dies potenziell ein Merkmal der Bilder verändert, welches charakteristisch für PV-Anlagen ist.

Beim Datensatz mit den Negativ-Beispielen wurden je Kategorie 10 Bilder für die Auswertung ausgewählt (also insgesamt 60 Bilder) und der Rest (1 450 Bilder) dem Trainingsdatensatz hinzugefügt.

Der finale Datensatz wurde in Trainings-, Validierungs- und Testdaten aufgeteilt.

Die Daten wurden je nach verwendetem Encoder für das Modell noch weiter vorbereitet. Für Vgg16 und Vgg19 wurden die RGB-Bilder in BGR umgewandelt und die Farbkanäle null-zentriert. Für DenseNet121 wurden Pixel auf den Bereich 0 bis 1 skaliert und die Kanäle normiert. Anschließend wurden die Bilder auf die Größe 256 erweitert, da die Unet-Architektur ein Vielfaches von 16 erfordert, die Bilder in der Inference Phase aber in der Größe 250 x 250 Pixel vorliegen müssen.

6.2.2 Model Finding und Training

Auf die vorbereiteten Daten wurden unterschiedliche Modelle angewendet und anhand des Dice-Koeffizienten (vgl. Abschnitt 6.1.3) verglichen.

Alle Modelle wurden in der Python-Bibliothek Keras implementiert und die Berechnungen auf einer Nvidia Quadro RTX 8000 durchgeführt. Die Implementierungen orientieren sich an [42]. Jedes Modell

wurde 200 Epochen trainiert. Dabei wurde die Early-Stopping-Methode mit Hyperparameter $s = 50$ angewandt. Die Batchsize betrug 32 und als Loss Funktion wurde der Dice-Loss verwendet.

Es wurden Varianten des Unets basierend auf [41] mit verschiedenen vortrainierten Encodern, Breiten, Tiefen und Dropout untersucht. Der Encoder Vgg16 lieferte dabei die besten Ergebnisse, weshalb er auch für eine Variante des Unet++ betrachtet wurde.

Die Modelle wurden mit unterschiedlichen Optimierern untersucht. Der Adam-Optimierer lieferte auf allen Modellen gute Ergebnisse, wogegen die Modelle, die mit dem SGD-Verfahren optimiert wurden, deutlich schlechter abschnitten. Alle Modelle wurden mit Batch-Normalization implementiert. Ohne Batch-Normalization war ein Training auf den Trainingsdatensatz mit Negativen nicht erfolgreich möglich. Bei gleichem Optimierer lagen fast alle getesteten Modelle nahe beieinander, was auf die starke Regularisierung durch die Batch-Normalization zurückzuführen sein könnte.

Aus den Gruppen Unet der Tiefe 4 (Unet 4), Unet der Tiefe 5 (Unet 5) und Unet++ wurde jeweils die beste Konfiguration weiter betrachtet.

Pretraining und Transfer Learning

Zur Untersuchung des Einflusses von Transfer Learning (vgl. Abschnitt 6.1.4) wurden die ausgewählten Modelle zunächst auf den Kalifornien-Datensatz trainiert, bevor sie auf dem GWI-Datensatz (ohne Negativbeispiele) eingesetzt wurden. Die Modelle wurden mit denselben Hyperparametern wie zuvor trainiert. Die Ergebnisse der Modelle auf dem Kalifornien-Datensatz sind recht ähnlich, wobei Unet 4 mit einem Test Dice-Koeffizienten von 93,55 % knapp am besten abschneidet und Unet 5 mit 93,23 % am schlechtesten.

Für das Transfer Learning auf dem GWI-Datensatz wurden zwei Varianten je Modell trainiert. Für Variante 1 wurden die Gewichte des Encoders auf den Werten aus dem Training auf dem Kalifornien-Datensatz eingefroren und ein Fine Tuning mit 20 Epochen und Learning Rate von 0,00001 durchgeführt. Bei der zweiten Variante blieben alle Gewichte trainierbar.

Insgesamt zeigt sich, dass die zweite Variante für alle Modelle bessere Ergebnisse erzielt als die erste Variante mit Fine Tuning. Das Fine Tuning hat bei keinem der Modelle zu einer besseren Generalisierung geführt, möglicherweise aufgrund der unterschiedlichen Auflösungen der Datensätze. Im Vergleich zu den Ergebnissen aus dem Pretraining konnte nur beim Unet++ mit Variante 2 das Ergebnis verbessert werden.

Training Negativbeispiele

Wie in Abschnitt 6.2.1 beschrieben, wurde der Trainingsdatensatz um 1 450 Negative erweitert, um die Falsch-Positiv-Rate bei der Segmentierung zu reduzieren. Dies sollte das Modell auf Merkmale wie Glasdächer oder Parkplätze sensibilisieren. Auf diesen Datensatz wurden wieder die besten Modelle von Unet 4, Unet 5 und Unet++ trainiert. In Abbildung 6-3 sind einige Vorhersagen der unterschiedlichen Modelle auf den erweiterten Trainingsdatensatz dargestellt.

Auf der Validierungsdatenmenge erzielen alle drei Modelle sehr ähnliche Ergebnisse, während auf den Testdaten Unet++ leicht besser abschneidet. Auch im Vergleich zu den Ergebnissen aus dem vorigen Abschnitt konnte der Test Dice-Koeffizient des Unet++ leicht verbessert werden (von 94,5 % auf 94,65 %), während er sich bei Unet 4 und Unet 5 leicht verschlechtert hat.

Allerdings haben sich bei allen Modellen die Ergebnisse für die Bilder aus dem Datensatz mit den Negativen deutlich verbessert. Vor allem in der Kategorie Glasoberflächen konnte der Dice-Koeffizient bei allen Modellen von unter 40 % auf über 80 % gesteigert werden, aber auch in den anderen Kategorien konnten Verbesserungen erzielt werden. Die große Verbesserung insbesondere in der Kategorie Glasoberflächen deutet darauf hin, dass im ursprünglichen Datensatz wenig Bilder

mit entsprechenden Strukturen vorhanden waren, und die korrekte negative Erkennung daher nicht gut trainiert werden konnte.

Werden nur die Bilder aus dem Negativ-Datensatz betrachtet, schneidet das Modell Unet4 am besten ab. Unet++ erzielt auf diesen Bildern die schlechtesten Ergebnisse.

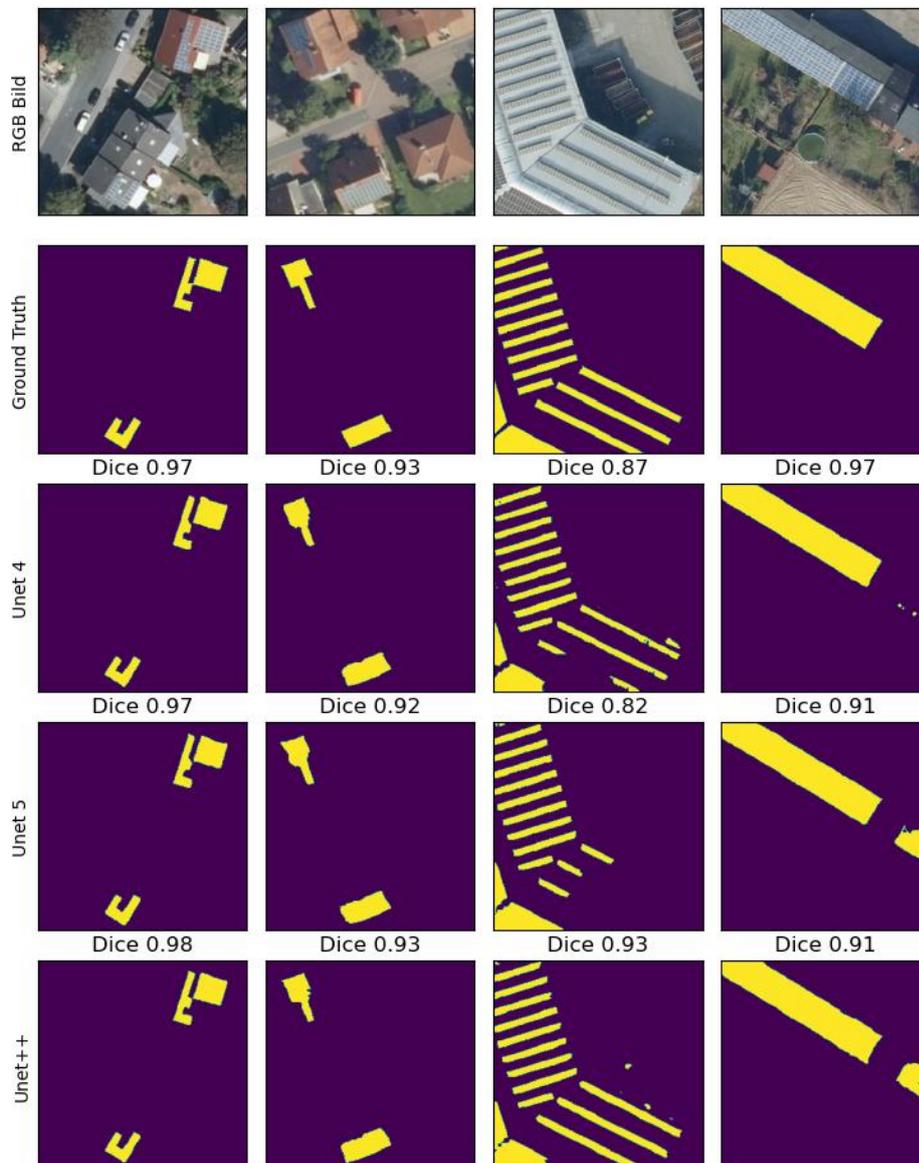


Abbildung 6-3: Vorhersagen auf den Trainingsdatensatz mit unterschiedlichen Modellen unter Angabe des Dice-Koeffizienten für das jeweilige Bild, Luftaufnahmen aus [44]

Threshold-Tuning

Die drei Modelle sollen auf ungesehenen, ungelabelten Daten verglichen werden. Dazu muss zunächst der optimale Threshold gefunden werden. Der Threshold bestimmt, ab welcher vorhergesagten Wahrscheinlichkeit ein Pixel als Teil einer PV-Anlage klassifiziert wird. Die Modelle geben als Vorhersage jeweils nur eine Wahrscheinlichkeit aus, mit der das jeweilige Pixel zu einer PV-Anlage gehört. Ziel ist es aber, die Flächen zu bestimmen, also zu jedem Pixel nur einen Boolean auszugeben, der aussagt, ob es sich um eine PV-Anlage handelt oder nicht.

Beim Threshold Tuning werden verschiedene Schwellenwerte getestet und der Einfluss des Thresholds auf die Modellergebnisse anhand des Testdatensatzes untersucht. Die Analyse hat

gezeigt, dass der Threshold das Modell Unet 4 am stärksten beeinflusst, mit einer maximalen Differenz der Dice-Koeffizienten von 0,07 %-Punkten. Bei den anderen beiden Modellen sind die Auswirkungen geringer, bei 0,02 %-Punkten (Unet 5) bzw. 0,03 %-Punkten (Unet++). Die Vorhersagen auf dem Testdatensatz waren meist sehr sicher (Wahrscheinlichkeiten über 0,9 oder unter 0,1), weshalb die Dice-Koeffizienten durch den Threshold nur geringfügig beeinflusst wurden. Daher wurden in den folgenden Auswertungen neben dem optimierten Threshold auch ein höherer Threshold von 0,7 betrachtet.

6.2.3 Anwendung und Validierung

Um die Performance der drei ausgewählten Modelle auf ungesehene, ungelabelte Daten zu vergleichen, wird das Marktstammdatenregister (MaStR) [24] herangezogen. Im MaStR sind die Bruttoleistungen der vorhandenen PV-Anlagen je Postleitzahl enthalten.

Um aus der Fläche der Modelle auf die Bruttoleistung zu schließen, wird ein Umrechnungsfaktor benötigt, der die Bruttoleistung pro Fläche inkl. der Umrechnung der waagerechten Flächen auf geneigte Flächen angibt. In der Literatur sind Werte zwischen 6 und 10 m²/kWp zu finden [46]-[49]. Da keine genaue Aussage über die real installierten Anlagen getroffen werden kann, wird je Modell der Faktor so gesetzt, dass der normierte, mittlere, absolute Fehler NMAE bezogen auf die Bruttoleistung minimiert wird. Dabei wird geprüft, ob sich der Faktor in einem realistischen Bereich befindet.

Die Modelle wurden auf drei ausgewählte Gemeinden (Dortmund, Unna und Borken) angewandt, welche die Stadtraumtypen städtisch, vorstädtisch und ländlich umfassen und 31 Postleitzahlengebiete beinhalten. Bei den Berechnungen wurden PV-Flächen unter 4 m² aussortiert und sowohl der optimierte als auch der höhere Threshold von 0,7 angewandt. Dies sollte falsch positiven Segmentierungen entgegenwirken. Wie auch schon auf dem Testdatensatz, war der Unterschied in den Ergebnissen mit optimiertem und höherem Threshold minimal. Für Unet 4 ergab sich, bezogen auf die vorhergesagte Fläche, eine Abweichung von ca. 1 %. Gegenüber dem Testdatensatz hat sich bei allen Modellen eine Verschlechterung ergeben. Dies deutet darauf hin, dass der Testdatensatz nicht komplett repräsentativ für die ausgewählten Gebiete ist.

Bei der Auswertung haben sich für die Modelle Faktoren zwischen 8,1 und 8,3 m²/kWp ergeben. Alle Werte liegen dementsprechend dicht zusammen und innerhalb des in der Literatur gefundenen Wertebereichs.

Bei Anwendung der unterschiedlichen Metriken ergeben sich für Unet 4 durchgängig die geringsten Fehler. In Tabelle 6-1 ist die prozentuale Abweichung der vorhergesagten Bruttoleistung je Gemeinde und Modell mit Threshold 0,7 von der Bruttoleistung laut MaStR dargestellt. Für Unet 4 ist auch hier die Abweichung für jede einzelne Gemeinde, aber auch in Summe am geringsten. Daher wurde für Unet 4 eine weitergehende Auswertung der Performance durchgeführt.

Tabelle 6-1: Prozentuale Abweichung der Bruttoleistungen in kWp der Modelle mit Threshold 0,7 von den Marktstammdaten für die Gemeinden Dortmund, Unna und Borken

Modell/Gemeinde	Dortmund	Unna	Borken	Summe
P_{PV} MaStR in kWp	45 135	12 200	51 551	108 886
Unet 4	10,35 %	13,88 %	-0,99 %	5,38 %
Unet 5	18,1 %	27,4 %	-2,42 %	9,43 %
Unet++	14,08 %	16,84 %	-4,04 %	5,81 %

Hierzu wurde das Modell auf Luftaufnahmen von 63 Postleitzahlengebieten angewendet und die Ergebnisse mit den Angaben im Marktstammdatenregister [24] verglichen, um die Performance auf einer größeren Menge an ungesehenen Daten zu evaluieren. Die Postleitzahlengebiete wurden semi-zufällig anhand von Bruttoleistung, Fläche, Einwohnerzahl und Einwohnerdichte ausgewählt, wobei in jeder Kategorie Postleitzahlgebiete mit hohen, niedrigen und mittleren Werten ausgewählt wurden.

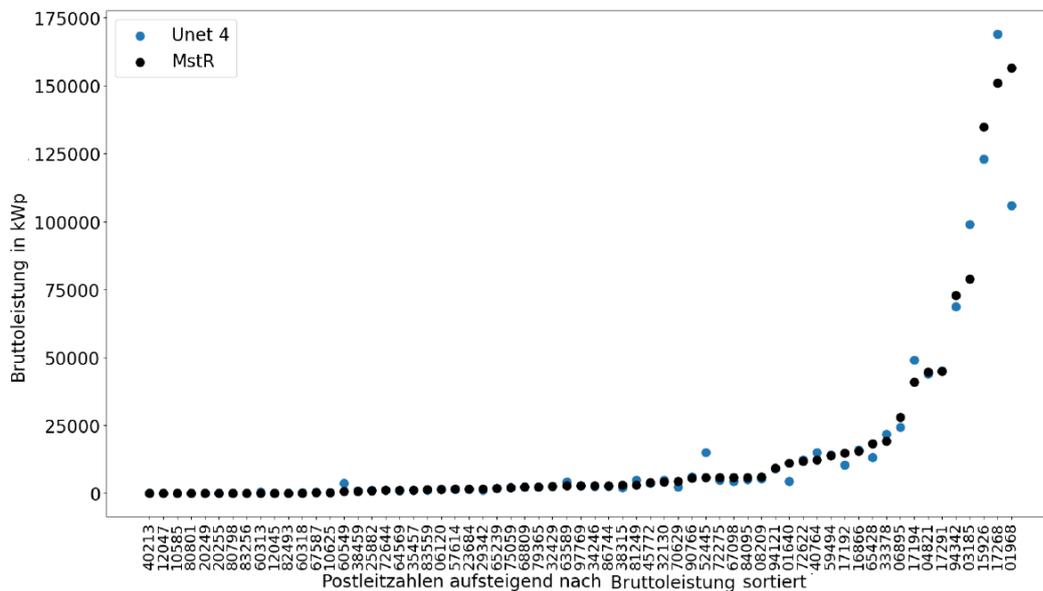


Abbildung 6-4: Vorhergesagte Bruttoleistung für 63 Postleitzahlengebiete mit Unet 4 und die korrespondierenden Werte aus dem Marktstammdatenregister

In Abbildung 6-4 sind die Ergebnisse der Vorhersage mit Unet 4 den Bruttoleistungen aus dem MaStR gegenübergestellt, aufsteigend nach Bruttoleistung sortiert. Es ist eine klare Korrelation zwischen den vorhergesagten Werten und den Marktstammdaten zu erkennen. Bei einigen Postleitzahlen kommt es jedoch zu Abweichungen. Eine Postleitzahl wurde stark überschätzt, da größere Felder als PV segmentiert wurden. Eine genauere Analyse der segmentierten Anlagen zeigte, dass auf den Bildern die Felder mit Planen abgedeckt waren, wodurch eine hohe Ähnlichkeit mit PV-Anlagen entstand. Zu dieser Struktur waren keine Bilder im Trainingsdatensatz enthalten. Eine andere Postleitzahl wurde unterschätzt, da große Anlagen nur teilweise segmentiert wurden. Der Faktor, der die Leistung pro Quadratmeter angibt, wurde bei 7,8 (Minimierung des NMAE) ermittelt. Insgesamt zeigte sich, dass das Modell in der Lage ist, auf verschiedenen Postleitzahlengebieten gute Ergebnisse zu liefern. Allerdings offenbarte es auch Schwächen, wie die teilweise Segmentierung ganzer landwirtschaftlicher Felder, die zu Überschätzungen führte. Diese Fehler können im Post-Processing korrigiert werden, indem große Segmentierungen mit Marktstammdaten und Landnutzungsdaten abgeglichen werden. Somit kann die Verteilung von Photovoltaikanlagen in Deutschland mit dem Modell in hoher räumlicher Auflösung mit guter Genauigkeit bestimmt werden.

Vergleich mit State-of-the-art

Die Ergebnisse wurden mit den State-of-the-art Ergebnissen aus anderen Veröffentlichungen verglichen. Es wird die Segmentierung und Klassifizierung auf der Testmenge untersucht und die Anwendung auf die drei Gemeinden Dortmund, Unna und Borken. Die Performance-Indikatoren bzw. Metriken der Veröffentlichungen (oben) und der im Rahmen des Projekts entwickelten Modelle (unten) sind in Tabelle 6-2 zusammengefasst.

Tabelle 6-2: Vergleich Segmentierungsergebnisse auf den Testsets

Paper	Dice in %	MAE in m ²	NMAE in %	MAPE in %	Bias in %
Deep Solar [50]	-	-	-	24,6	3
Deep Solar Germany [37]	-	17,47	23,34	21,73	0,54
3D Locator [49]	-	-	-	18,5	3,9
PV und Wind [51]	94	-	-	-	-
Fast Deep Learning [41]	92,84	-	-	-	-
Modell					
Unet 4	94,37	7,26	4,17	14,45	1,84
Unet 5	94,35	7,3	4,18	14,22	1,05
Unet++	94,65	7,16	4,14	13,5	1,42

Obwohl die Modelle auf unterschiedlichen Daten agieren, bewegen sich die Ergebnisse dieser Arbeit im vergleichbaren Rahmen wie in den anderen Veröffentlichungen. Die Verwendung von Bildern ohne PV-Anlagen (extra Datensatz mit Negativen) erhöht den Dice-Koeffizienten im Schnitt etwas, was in den Modellen und in [51] zu etwas besseren Werten führt als in [41].

Beim MAE und NMAE sind im Vergleich zu Deep Solar Germany [37] deutliche Unterschiede zu erkennen. Dies ist möglicherweise darauf zurückzuführen, dass unterschiedliche Bildgrößen verwendet wurden.

In [49] wurden auch Prädiktionen für die PV-Flächen in Dortmund, Unna und Borken bestimmt und mit den Marktstammdaten verglichen. Bezogen auf die Stadt Dortmund kommt die Veröffentlichung auf bessere Ergebnisse (Unterschätzung der Bruttoleistung von 6,95 % im Vergleich zu 10,35 % Überschätzung mit Unet 4 vgl. Tabelle 6-1). In Unna und Borken sowie im Vergleich zur Summe der drei Gemeinden sind die Abweichungen des Unet 4 Modells geringer als in der Veröffentlichung. Auch Unet++ zeigt insgesamt leicht bessere Ergebnisse als die Veröffentlichung. Beim Unet 5 Modell wird die PV-Leistung nur für Borken besser vorhergesagt. Insgesamt wird in den entwickelten Modellen die Leistung tendenziell eher überschätzt, während in [49] die Leistung eher unterschätzt wird. In der Veröffentlichung wird der Anwendung der Segmentierung eine Klassifikation vorgeschaltet. Möglicherweise werden dadurch einige Bilder nicht als PV klassifiziert und damit gar nicht segmentiert. Allerdings ist generell die Vergleichbarkeit mit [49] nur eingeschränkt gegeben, da dort die industriellen Anlagen entfernt wurden, während in diesem Projekt die industriellen Anlagen mitbetrachtet wurden.

Obwohl keins der aufgeführten Veröffentlichungen auf die exakt gleichen Datenmengen angewendet wurde und damit kein direkter Vergleich möglich ist, lässt sich doch erkennen, dass sich die Ergebnisse für die Metriken der verwendeten Modelle insgesamt in einem ähnlichen Rahmen wie die Veröffentlichungen bewegen oder sogar etwas bessere Ergebnisse liefern. Da Unet 4 dabei wie oben beschrieben tendenziell die besten Ergebnisse der untersuchten Modelle liefert, wird dieses Modell für die weitere Verwendung ausgewählt.

6.3 Räumlich-energetische Charakterisierung der EE-Erzeugung

Im Rahmen des Projekts soll anhand der Beispielregion Münster eine detaillierte Simulation der Erzeugung, des Verbrauchs und der resultierenden Ausgleichsströme durchgeführt werden. Um ein

hohes interregionales Ausgleichspotenzial betrachten zu können, sollte die gewählte Region sowohl urbane Gemeinden, aber auch ländliche Regionen, die weniger stark besiedelt sind, beinhalten. Der Regierungsbezirk Münster, zu dem Städte wie Borken, Bottrop, Coesfeld, Gelsenkirchen, Münster und Recklinghausen gehören (siehe Abbildung 6-5), besteht insgesamt aus 78 Gemeinden und hat eine Einwohnerzahl von ca. 2,62 Millionen, was ca. 15 % der Bevölkerung aus Nordrhein-Westfalen (NRW) entspricht. In Abbildung 6-5 ist die Einwohnerzahl für die zwanzig einwohnerstärksten Gemeinden dargestellt. Dazu zählen insbesondere die Gemeinden Münster und Gelsenkirchen.

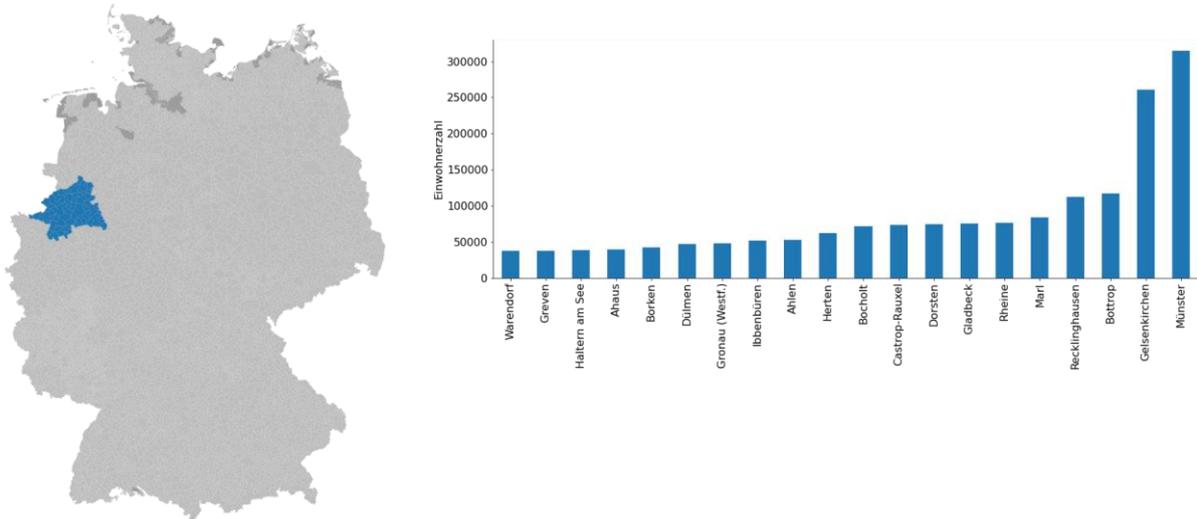


Abbildung 6-5: Regierungskreis Münster (links) und Einwohnerzahl der 20 einwohnerstärksten Gemeinden im Regierungskreis Münster (rechts).

Aus Abbildung 6-6 ist der Anteil der Gemeinden bzw. der NUTS3 Regionen an der Bevölkerung im Regierungsbezirk Münster ersichtlich. Die Städte im Süden des Regierungsbezirks und Münster selbst haben einen großen Anteil an der Bevölkerung und Marl ist Standort eines der größten Industrieparks Deutschlands, während die übrige Region eher ländlich geprägt ist. Diese Verteilung ist ein erster Anhaltspunkt für die räumliche Verteilung der Energiebedarfe.

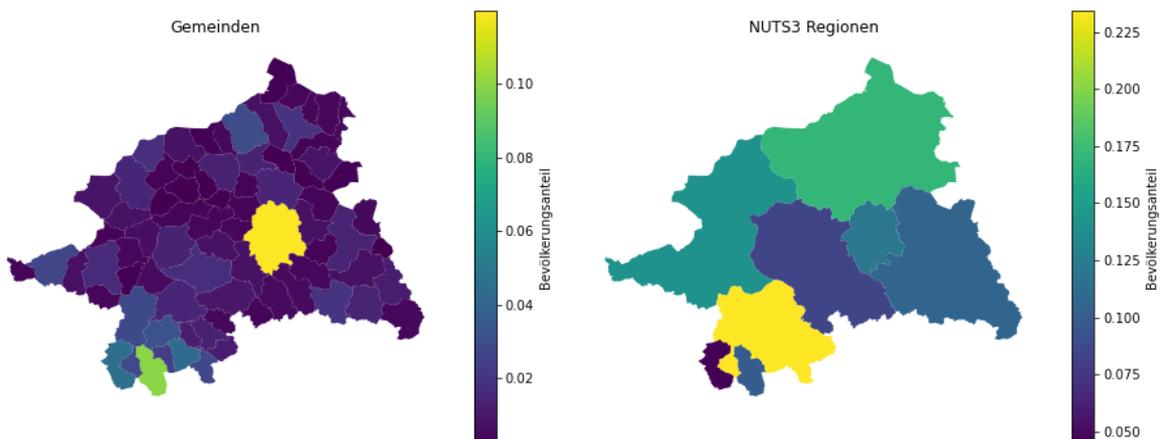


Abbildung 6-6: Bevölkerungsanteil der Gemeinden (links) und NUTS3 Regionen (rechts) des Regierungsbezirks Münster.

6.3.1 Photovoltaik

Für den Kreis Münster (NUTS2 DEA3) lag laut Marktstammdatenregister [24] im Jahr 2019 eine installierte PV-Leistung von rund 1 320 MW (~62 000 Anlagen) vor. Das entsprach ca. 27 % der installierten Leistung in NRW (~4 900 MW).

In Abbildung 6-7 ist auf der linken Seite die geographische Verortung der PV-Anlagen (> 30 kW) in der Region Münster laut semantischer Segmentierung abgebildet. Rechts sind die PV-Anlagen-Leistungen je Gemeinde mit den Daten aus dem MaStR dargestellt. Besonders hohe Anlagenleistungen ergeben sich demnach für Münster, für Borken und für Ahaus. In der Region nordöstlich von Münster (Lengerich, Tecklenburg, Landbergen und Lienen) sind die geringsten PV-Anlagenleistungen installiert. In dieser Region wurden auch weniger große PV-Anlagen identifiziert, was an der geringeren Dichte der Punkte im linken Teil der Abbildung erkennbar ist.

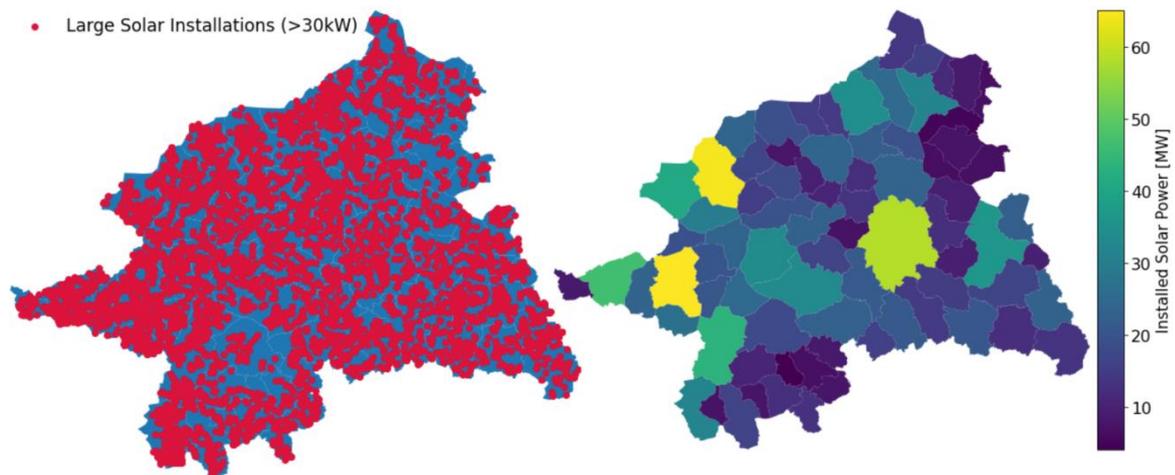


Abbildung 6-7: Geographische Lokalisierung der PV-Anlagen (links) aus der semantischen Segmentierung und die installierte Leistung (rechts) in der Region Münster für 2019 je Gemeinde, berechnet aus [24]

Aus den identifizierten Flächen mit PV-Anlagen (s. Kapitel 6.2) werden, über die Umrechnung auf die installierte Leistung, Zeitreihen für die Stromerzeugung berechnet. Um von den Flächen in den einzelnen Hexagonen auf die PV-Anlagen-Leistung zu schließen, wird anhand der Leistung je Postleitzahlgebiet aus den Marktstammdaten der Skalierungs-faktor α bestimmt. Hierzu werden die Flächen zunächst auf die Postleitzahlgebiete aggregiert und α je Postleitzahlgebiet so gewählt, dass die Gesamtleistung der in den Marktstammdaten angegebenen Leistung entspricht. Der Faktor wird dann auf jedes Hexagon angewandt, um die installierte Anlagen-Leistung auf Hexagonebene zu bestimmen.

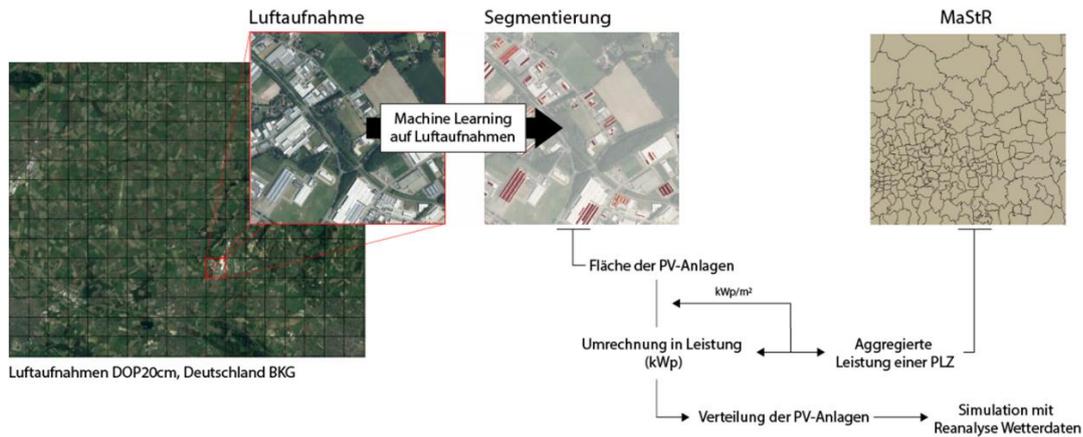


Abbildung 6-8: Methodik: Segmentierung der PV-Anlagen und Skalierung der Ergebnisse mit Marktstammdaten. Luftaufnahmen aus [44]

Die Globalstrahlungsdaten sind im Wetter-Reanalyse-Datensatz ERA5 [52] enthalten. Aus der Fläche A_{pv} , dem Faktor α und der Globalstrahlung G_{ERA5} lassen sich die Zeitreihen für die erzeugte PV-Leistung berechnen mit:

$$P_{pv}(t) = G_{ERA5}(t) * A_{pv} * \alpha$$

Die so erzeugten PV-Einspeisezeitreihen je Hexagon werden im Gesamtmodell für das Basisszenario verwendet (vgl. Abschnitt 8.2). In Abbildung 6-8 ist der gesamte Ablauf zur Bestimmung der PV-Erzeugung grafisch dargestellt.

6.3.2 Windkraft

Als Datengrundlage für die Bestimmung der durch Windkraft erzeugten Leistung im Regierungsbezirk Münster dient ebenfalls das Marktstammdatenregister (MaStR) [24]. Dort ist für das Jahr 2019 eine installierte Leistung von rund 1 668 MW angegeben (950 Anlagen), was ca. 29 % der gesamten installierten Leistung in NRW ausmacht, siehe Abbildung 6-9.

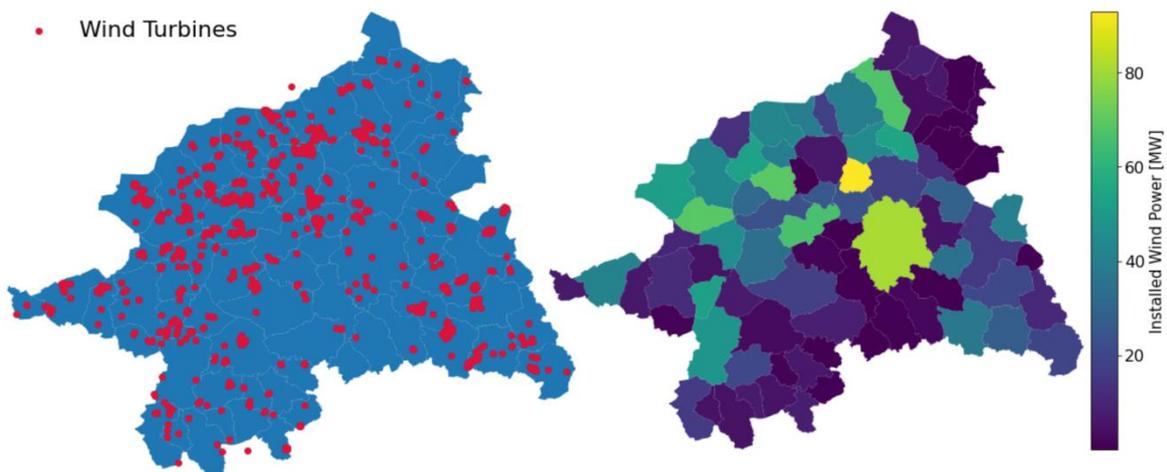


Abbildung 6-9: Geografische Lokalisierung der Windkraftanlagen (links) und die somit installierte Leistung (rechts) in der Region Münster. Nach MaStR (2019) 1 668 MW (950 Anlagen), ca. 29% der installierten Leistung in NRW (5729 MW).

Für die Berechnungen wurden auf den ERA5-Reanalyse Datensatz (Copernicus) mit stündlicher Auflösung der Windgeschwindigkeiten und Bodenrauigkeit zurückgegriffen [52]. Zusammen mit den Angaben aus dem MaStR, welche neben der Anzahl und Position auch die Nabhöhe,

Rotordurchmesser und Nennleistung umfassen, konnte die tatsächlich erzeugte Leistung der Anlagen bestimmt werden.

Im Vorfeld der Berechnungen werden fehlende oder fehlerhafte Angaben zum Standort oder den Anlagedaten korrigiert oder ergänzt. Im Fall von fehlerhaften Angaben zum Standort werden mittels Geocoding (bspw. über Straße + Postleitzahl) Koordinaten zugewiesen. Fehlende Anlagedaten werden ergänzt mittels linearer Regression vorhandener Angaben. Der schematische Ablauf zur Berechnung der Erzeugung ist abgebildet in Abbildung 6-10.

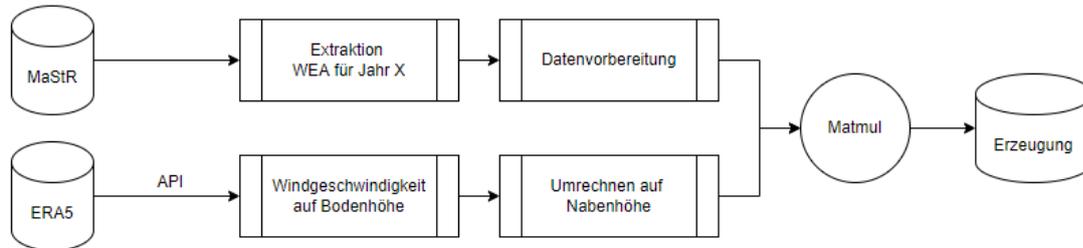


Abbildung 6-10: Schematische Darstellung zur Berechnung der erzeugten Windenergie für das Jahr 2019

Für die Bestimmung der zeitlich aufgelösten Stromerzeugung wird zunächst die Windgeschwindigkeit von Boden- auf Nabenhöhe umgerechnet:

$$v_2 = \frac{\log\left(\frac{h}{z_0}\right)}{\log\left(\frac{10}{z_0}\right)} * v_1$$

wobei h die Nabenhöhe ist, z_0 die Bodenrauigkeit und v_1 die Bodenwindgeschwindigkeit und v_2 die Geschwindigkeit auf Nabenhöhe. Aus der berechneten Windgeschwindigkeit v_2 lässt sich die Leistung bestimmen:

$$P(t) = 0.5 * c_p * \rho_{\text{air}} * A * v_2(t)^3$$

Der Leistungskoeffizient $c_p(v_2)$ wird mit Hilfe der *openenergy wind_turbine_library* berechnet [53]. Die Abregelung der Anlagen setzt ein bei: $v_2 = 0 \{v_2 \leq 2 \text{ m/s}; v_2 > 23 \text{ m/s}\}$. Durch Kombination von Anlagedaten, Wetterdaten und Bodenrauigkeit werden die Daten über eine Matrixmultiplikation verrechnet, um die anlagespezifischen Zeitreihen zu generieren. Netzbedingte Abregelungen, sowie Windparkeffekte wie z.B. Windschatten, wurden bei der Berechnung der produzierten Leistung nicht berücksichtigt, daher fällt die berechnete Leistung tendenziell etwas höher aus als die in Statistiken angegebene Leistung. Die nach obenstehender Formel berechneten und Hexagon-spezifisch aufgelösten Zeitreihen werden im Basisszenario verwendet (vgl. Abschnitt 8.2).

6.3.3 Ausbaupotenziale von Photovoltaik und Windkraft

Um für die Szenarien den Ausbau von Photovoltaik und Windkraft zu betrachten, wird eine Angabe für das Ausbaupotenzial je Energiezelle benötigt, um keinen Ausbau, der über das maximale Potenzial hinausgeht, anzunehmen. Dafür wird auf Open Source Geodaten für Photovoltaik- und Windkraftpotenziale zurückgegriffen, die in Relation mit dem Ausbaustand von 2019 gesetzt werden. Für Photovoltaik-Freiflächenanlagen und für PV-geeignete Dachflächen wird dafür auf Daten von OpenGeodata.NRW zurückgegriffen [54]. Die Daten beinhalten für PV geeignete Flächen mit einer Abschätzung, wie viel Leistung jeweils installiert werden könnte. Für die Windkraftpotenziale wird der Datensatz „Potenzialflächen der Flächenanalyse Windenergie NRW“ vom Landesamt für Natur, Umwelt und Verbraucherschutz Nordrhein-Westfalen (LANUV) verwendet. Darin enthalten sind für Windenergie potenziell geeignete Flächen. Um die potenziell installierbare Leistung zu erhalten,

wurde eine typische Windkraftanlage mit einer Nennleistung von 3,5 MW und einer Nabenhöhe von 150 m angenommen (in Anlehnung an [55]). Aufgrund der Faustregel, dass der Abstand zwischen Windkraftanlagen in Hauptwindrichtung mindestens fünf Rotordurchmesser betragen soll [56], wird für Anlagen ein Flächenbedarf von $150 \times 150 \text{ m}^2$ angenommen. Dieser Flächenbedarf wird angewendet, wenn eine Potenzialfläche größer als ebendieser Flächenbedarf ist.

Für Windkraft und Photovoltaik ist der Stand des Ausbaus 2019 im Vergleich zum Potenzial je Hexagon in Abbildung 6-11 für Windkraft bzw. in Abbildung 6-12 für PV abgebildet.

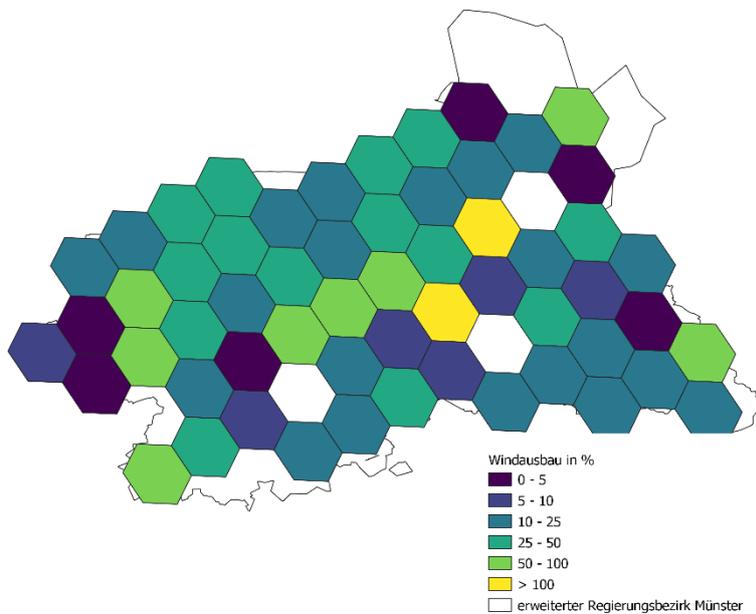


Abbildung 6-11: Anteil des Windkraftausbaus am Potenzial je Hexagon im betrachteten Gebiet.

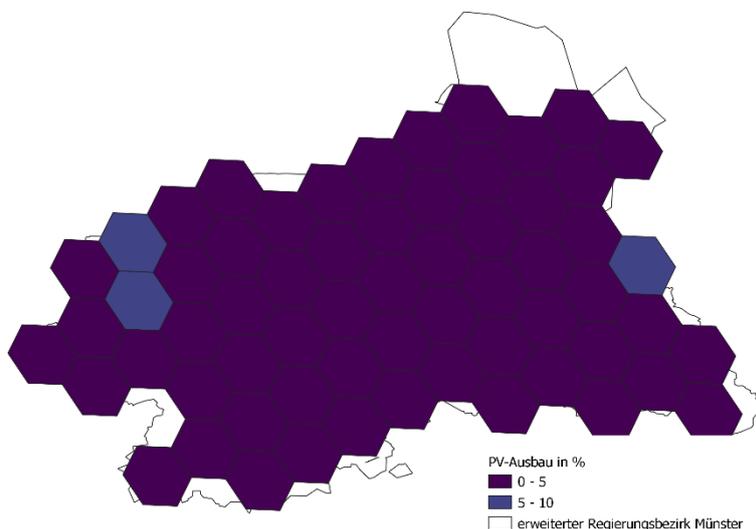


Abbildung 6-12: Anteil des Photovoltaikausbaus am Potenzial je Hexagon im betrachteten Gebiet.

Das Zukunftsszenario für den Windkraft- und Photovoltaikausbau orientiert sich an Szenario B des Netzentwicklungsplans (siehe [57]). Für 2037 wird für Windkraft ein Ausbau von rund 25 % angenommen und für Photovoltaik 15 %. Dieser prozentuale Ausbau wird auf jede Zelle übertragen, weil davon ausgegangen wird, dass Regionen, die heute schon den Ausbau forciert haben, auch in Zukunft tendenziell weiter stark ausbauen. Das Windkraftpotenzial ist in drei Zellen rechnerisch

schon zu über 90 % genutzt. Für diese Zellen wird kein weiterer Ausbau angenommen und die für die Zielerreichung benötigte Leistung auf die anderen Zellen aufgeteilt. Dadurch ergibt sich für die restlichen Zellen bezogen auf die Windkraft ein Zubau von 27,5 %.

6.4 Energiebedarfe

Als Grundlage für die Energiebedarfe werden die Ergebnisse aus dem Forschungsprojekt DemandRegio [58] verwendet. In DemandRegio wurden sowohl für Strom als auch für Gas Lastprofile auf Landkreisebene (NUTS3) simuliert. In Tabelle 6-3 ist der Energiebedarf für Deutschland sowie für den Regierungsbezirk Münster im Jahr 2019 angegeben.

Tabelle 6-3: Strom- und Gasbedarf Deutschlands und des Regierungsbezirks Münster 2019 [58]

2019		Haushalte [TWh]	Gewerbe [TWh]	Industrie [TWh]
Deutschland	Strom	128,9	144,4	221,6
	Gas	274,6	107,4	324
Regierungsbezirk Münster	Strom	4,8	4,3	7,4
	Gas	9,2	3,6	10,9

Daten für eine höhere geographische Auflösung des Energiebedarfs als die Landkreisebene sind in der Literatur nicht vorhanden, daher werden die Energiebedarfe über Verteilungsschlüssel auf einzelne H3-Zellen disaggregiert. Ziel ist es, für jede Zelle und jeden Sektor in der Region Münster ein eigenes Lastprofil zu generieren. Die Verteilungsschlüssel werden in den folgenden Unterkapiteln beschrieben.

Strom-/Gasverbrauch auf Landkreisebene

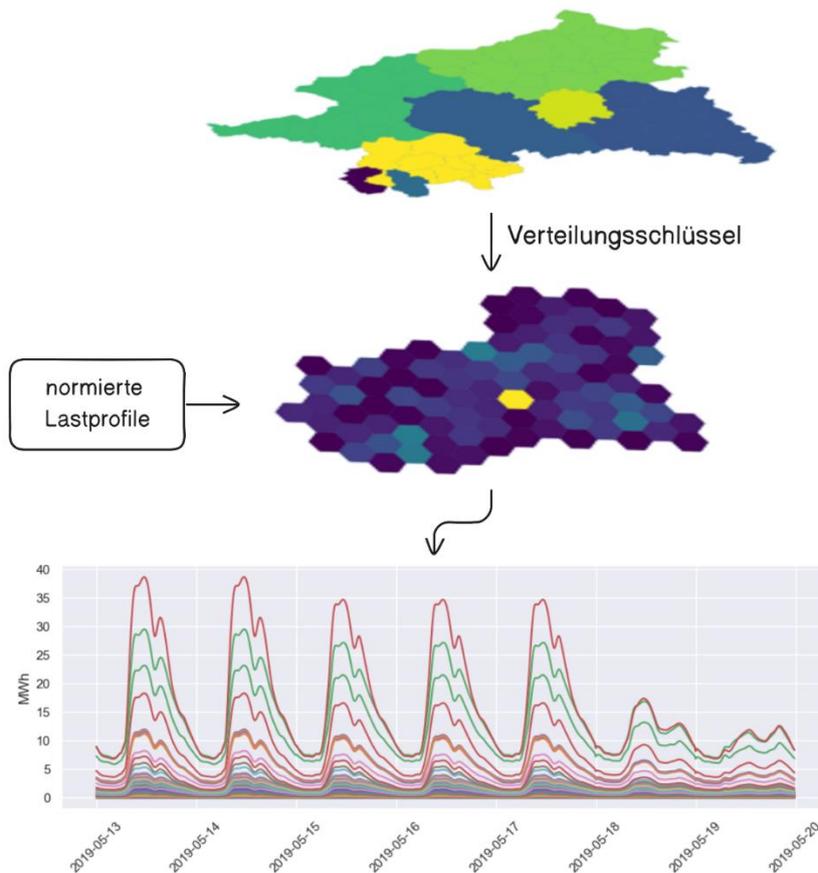


Abbildung 6-13: Methodik zur Generierung zellspezifischer Lastprofile für die Region Münster

Es wird für jeden Sektor ein Top-Down Ansatz gewählt, sodass die Bilanz der Energiebedarfe aus den H3-Zellen, zurück auf die Landkreisebene aggregiert, jeweils mit den Bedarfen der DemandRegion-Lastprofile übereinstimmt. Dabei ist die Methodik die gleiche für jeden Sektor, wobei je nach Sektor auf verschiedene Datensätze und Verteilungsschlüssel zurückgegriffen wird. Eine allgemeine Darstellung der Methodik zur Generierung von zellspezifischen Lastprofilen gibt Abbildung 6-13. In den folgenden Kapiteln wird das genaue Vorgehen für jeden Sektor aufgeführt.

6.4.1 GHD-Sektor

In der Regel wird bei der Beschreibung des Energiebedarfs auf Landkreisebene, ähnlich wie im Industriesektor, die Bruttowertschöpfung oder die Anzahl der Erwerbstätigen als Verteilungsschlüssel verwendet, um Bundesstatistiken zu extrapolieren. Aufgrund der begrenzten Verfügbarkeit solcher Angaben auf einer feineren geografischen Ebene wird in diesem Fall stattdessen die Gewerbefläche als Indikator herangezogen. Diese Flächeninformationen werden aus den Geodaten Level of Detail 1 (LOD1) des Landes Nordrhein-Westfalen sowie aus OpenStreetMap (OSM)-Daten gewonnen.

Anhand der Gebäudefunktion kann die Zugehörigkeit eines Gebäudes zum Gewerbesektor bestimmt werden, wobei die entsprechende Gewerbefläche GF anhand geografischer Funktionen ermittelt wird. Die OSM-Daten ergänzen die LOD1-Daten dort, wo präzisere Informationen zur Gebäudefunktion verfügbar sind. Die so ermittelten Gewerbeflächen GF werden auf Landkreisebene lk aufsummiert. Daraus ergibt sich für den Verbrauchsfaktor x im Gewerbesektor G für den Strom- und Gasverbrauch W folgender Zusammenhang:

$$x_{lk}^G \left[\frac{kWh}{m^2} \right] = \frac{W_{lk} [kWh]}{GF_{lk} [m^2]}$$

Mit Hilfe des Verbrauchsfaktors wird jedem einzelnen Gebäude ein Verbrauch zugewiesen. Anschließend erfolgt die Aggregation des Verbrauchs auf die Ebene der H3-Hexagone. Im letzten Schritt werden dann die Lastprofile für jedes H3-Hexagon entsprechend dem spezifischen Verbrauch in jeder Zelle generiert. Diese Lastprofile dienen als Input für die nachfolgende Simulation und Sektorenanalyse.

6.4.2 Industrie-Sektor

Für den Industriesektor wird ein ähnlicher Ansatz wie für den GHD-Sektor gewählt, wobei die Verteilung des Energiebedarfs im Industriesektor teilweise stark von einzelnen Standorten, insbesondere Industrie- und Chemieparks, beeinflusst wird. Um dies zu berücksichtigen, werden größere Industriestandorte mit ihren zugehörigen Industrieflächen gesondert berücksichtigt.

Als Basisdatensatz dienen erneut die LOD1-Geodaten. Die Fläche der Industriegebäude IF wird in diesem Fall ebenfalls als Verteilungsschlüssel verwendet. Da der tatsächliche Energiebedarf pro Fläche je nach Betrieb erheblich variieren kann, ist dies grundsätzlich kein optimaler Parameter für die Bestimmung des Energiebedarfs. Allerdings kann mit einem Top-Down Ansatz mit Hilfe der Gebäudefläche der Energiebedarf von der Landkreisebene auf die Gebäudeebene qualitativ verortet werden. Die Bestimmung des Verbrauchsfaktors im Industriesektor I berechnet sich wie folgt:

$$x_{lk}^I \left[\frac{kWh}{m^2} \right] = \frac{W_{lk} [kWh]}{IF_{lk} [m^2]}$$

Die Berechnung des Verbrauchsfaktors sowie die nachfolgende Generierung der Lastprofile für jedes Hexagon ist analog zum Gewerbesektor. Im Gegensatz zum Gewerbesektor gibt es im Industriesektor einige Gebiete, in denen keine Industriegebäude jeglicher Art erfasst werden, welche dementsprechend in Lastprofilen ohne Verbrauch resultieren.

6.4.3 Wohngebäudesektor

Im Bereich des Wohngebäudesektors können übliche Verteilungsfaktoren, wie die Anzahl der Haushalte oder die Bevölkerungszahl, als Grundlage verwendet werden. Als Datengrundlage dienen die Ergebnisse des Zensus von 2011. Diese Daten liegen nicht in einer gebäudespezifischen Form vor, sondern sind in 100x100 Meter Rastern verfügbar. Aus diesem Grund wird im Haushaltssektor H der Energieverbrauch rasterbezogen zugeteilt.

$$x_{lk}^H \left[\frac{kWh}{P} \right] = \frac{W_{lk} [kWh]}{n_p}$$

Die Zuweisung erfolgt analog unter Verwendung des Verbrauchsfaktors x , wobei der Verteilungsfaktor im Haushaltssektor die Anzahl der Personen pro Landkreis ist, hier angegeben mit n_p . Allerdings gestaltet sich dieser Schritt im Vergleich zu den anderen Sektoren als herausfordernder, da die Zensus-Daten keine direkte Zuordnung zu Landkreisen oder Gemeinden enthalten. Daher ist eine geografische Analyse erforderlich, um diese Zuordnung vorzunehmen, was sich in erheblicher Berechnungszeit niederschlägt.

6.4.4 Fortschreibung Zukunftsszenarien

Die Fortschreibung der Energiebedarfe orientiert sich am Szenario B des Netzentwicklungsplans Strom sowie an der Studie „Klimaneutrales Deutschland 2045“ [59] [60]. Aus letzter wurden die Angaben zum Wärmebedarf und der zur Verfügung stehenden Wasserstoffmenge entnommen. Eine Übersicht über die dem Modell zugrundeliegenden Strombedarfe gibt Tabelle 6-4. Der berechnete Wärmebedarf für die Region Münster ist in Abbildung 6-14 zu sehen.

Tabelle 6-4: Stromverbrauch Deutschlands und des Regierungsbezirks Münster im Zukunftsszenario [59]

	Haushalte [TWh]	Gewerbe [TWh]	Industrie [TWh]
Deutschland	157,1	167,9	334,0
Regierungsbezirk Münster	5,9	5,0	11,2

In der Studie „Klimaneutrales Deutschland 2045“ ist für die Sektoren Haushalte und GHD der aufgewendete Endenergieverbrauch für die Wärmeversorgung kombiniert angegeben. Die Aufteilung auf die beiden Sektoren erfolgt gemäß heutiger Endenergieverteilung auf die Sektoren Haushalte, GHD und Industrie [61]. Im Industriesektor wird der gesamte Endenergieverbrauch angegeben, daher wird für die Wärmebedarfsberechnung die Angabe für Strom nicht berücksichtigt. Das Modellszenario bezieht sich auf kein spezifisches Jahr, allerdings wurden zur Orientierung die Werte aus dem Stützjahr 2040 herangezogen [60].

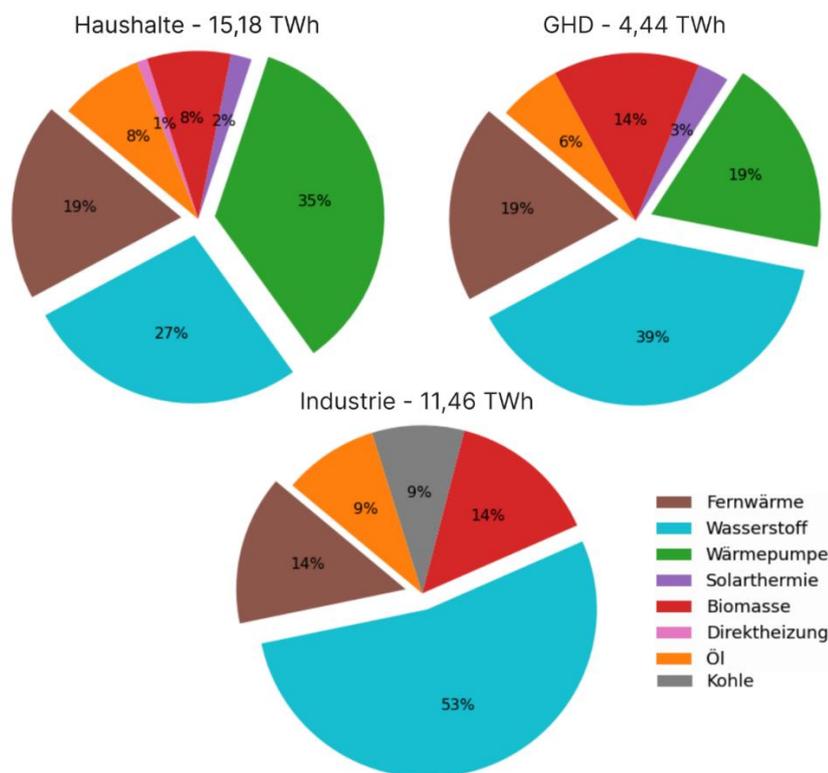


Abbildung 6-14: Wärmebedarfsstruktur der Sektoren Haushalte, GHD und Industrie für die Region Münster im Zukunftsszenario (eigene Berechnungen basierend auf [60]).

Sowohl die Angaben zum Strombedarf als auch die Endenergiebedarfswerte für die Wärmeversorgung sind für Deutschland angegeben und werden im Modell anhand des heutigen prozentualen Anteils jeweiliger Strom- und Gasbedarfe auf die Region Münster bezogen. Diese machen etwa 3 % des deutschlandweiten Verbrauchs aus. Unter Berücksichtigung der Beheizungsstruktur der Wohn- und Gebäudefläche ergibt sich für die Region Münster eine Wärmebedarfsstruktur, die sich durch hohe Anteile an Wärmepumpen und Wasserstoff kennzeichnet, siehe Abbildung 6-14.

Durch die zunehmende Elektrifizierung des Wärmesektors wird ein Großteil des Wärmebedarfs in allen Sektoren durch Strom gedeckt werden. Über Angaben zum anteiligen Strombedarfs von

Wärmepumpen im Jahr 2037, sowie der Jahresarbeitszahl [59] lässt sich der durch Wärmepumpen gedeckte Anteil des Wärmebedarfs in den Sektoren Haushalte und GHD berechnen.

$$Q^{WP} = P_{el} * JAZ * a_{Münster}$$

Des Weiteren ist aus den Angaben zum Stromverbrauch von Wärmepumpen für Fernwärme [59] sowie des Anteils der für Fernwärme vorgesehenen Ausspeiseleistung an Wasserstoff [60] eine Fernwärmeleistung berechenbar, die zusätzlich zu lokalen Wärmepumpen einen erheblichen Anteil des gesamten Wärmebedarfs deckt. Der in Abbildung 6-14 erkennbare, höhere Anteil von Wasserstoff an der Wärmeversorgung im Industriesektor beruht darauf, dass nur ein Teil des Wasserstoffs für die Fernwärmeerzeugung verwendet wird und sich die übrige Nachfrage aus Unternehmen der Industriezweige Stahlproduktion, Grundstoffchemie etc. zusammensetzt.

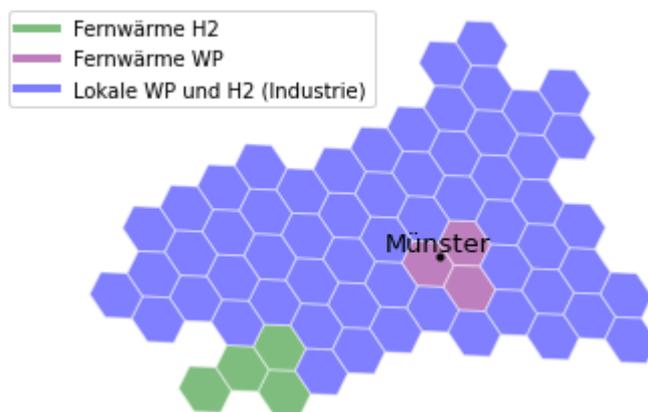


Abbildung 6-15: Wärme-Versorgungsstruktur einzelner Hexagone in der Region Münster im Zukunftsszenario.

Um geeignete Hexagone für Fernwärmeversorgung in der Region Münster zu ermitteln, wurden bestehende Fernwärmenetze und das Ausbaupotenzial für Fernwärme analysiert. Gleichzeitig wurden die Leistungen der verschiedenen Energieträger in jedem Sektor von der Deutschlandebene auf die Region Münster herunterskaliert, basierend auf Daten aus der Studie "Klimaneutrales Deutschland 2045" und dem Netzentwicklungsplan 2037. Die Versorgung des Wärmebedarfs in den einzelnen Hexagonen, entsprechend der für die Region Münster verfügbaren Leistung, ist in Abbildung 6-15 dargestellt, wobei in den durch Fernwärme versorgten Hexagonen eine Anschlussquote von 80 % angenommen wird.

Abschließend wurden hexagon- und sektorspezifische Lastprofile unter Verwendung der Lastprofile aus dem DemandRegio-Projekt [58] und einem Wärmepumpenlastprofil gemäß dem VDN-Praxisleitfaden „Lastprofile für unterbrechbare Verbrauchseinrichtungen“ generiert [62].

6.5 Räumlich-zeitliche Charakterisierung der Residuallasten

Durch das Zusammenführen der Profile für Wind- und PV-Erzeugung (s. Abschnitt 6.3) sowie der Bedarfsprofile der Sektoren Haushalte, GHD und Industrie (s. Abschnitt 6.4) lässt sich eine örtlich und zeitlich aufgelöste Residuallast ermitteln. Die hohe Auflösung der Residuallast ermöglicht es Potenziale für die Sektorenkopplung zu ermitteln.

In Abbildung 6-16 ist die Erzeugung, der Verbrauch und die daraus resultierende Residuallast für das Jahr 2019 hexagonspezifisch dargestellt. Besonders hohe Erzeugungsleistungen lassen sich in den ländlichen Regionen im Norden des Regierungsbezirks Münster erkennen, wohingegen der größte Verbrauch eher im Süden, den Ausläufern des Ruhrgebiets, verortet ist.

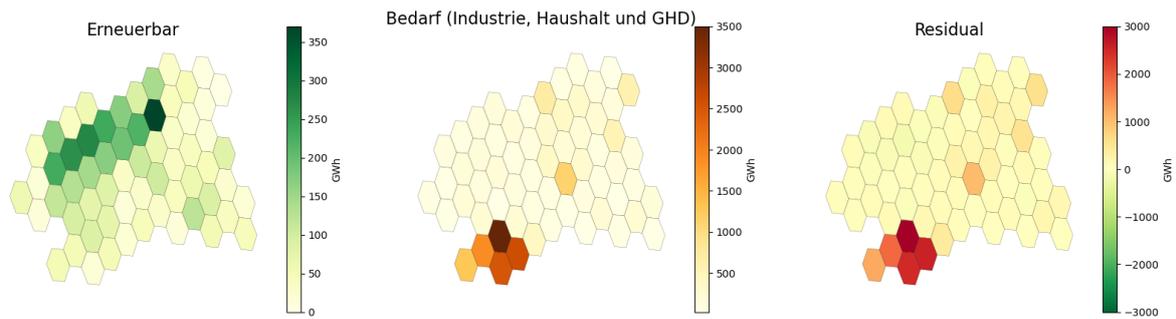


Abbildung 6-16: Hexagonspezifische Darstellung der Erzeugungs- und Verbrauchsstruktur im Regierungsbezirk Münster, sowie der daraus resultierenden Residuallast für das Jahr 2019.

Aufgrund des in Marl ansässigen Chemieparks ist hier das Hexagon mit dem höchsten Jahresverbrauch anzufinden. Trotz geringeren Verbrauchs ist die Stadt Münster im Zentrum des Regierungsbezirks deutlich erkennbar.

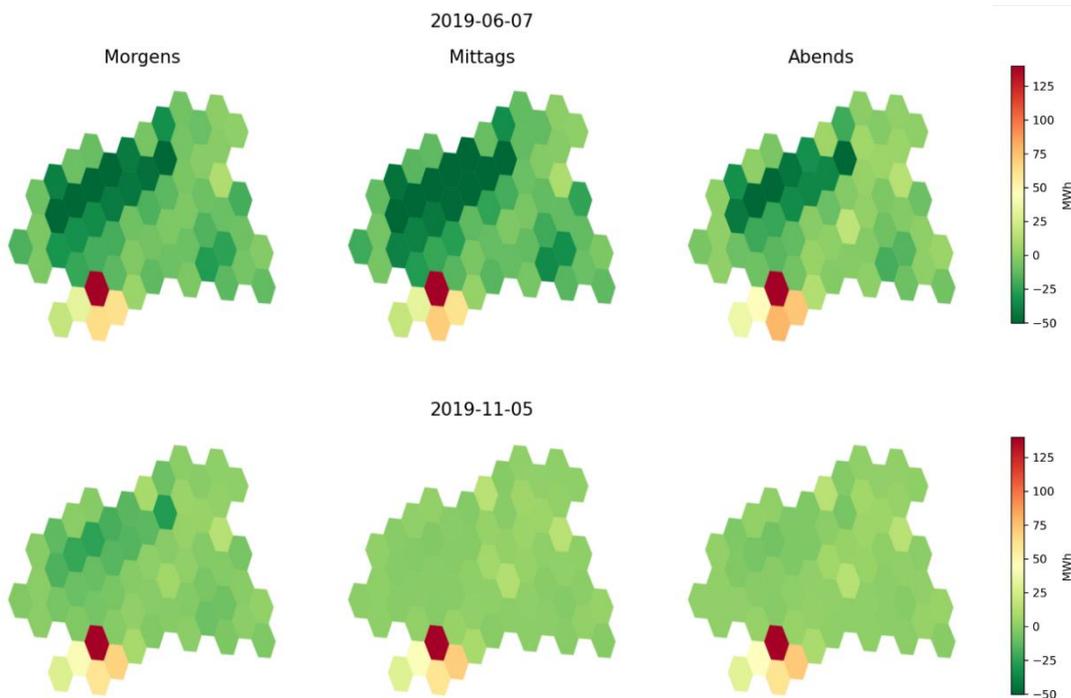


Abbildung 6-17: Hexagonspezifische Residuallastverteilung im Regierungsbezirk Münster am Beispiel eines Tags im Sommer (oben) und im Winter (unten) für das Jahr 2019.

Die Analyse des zeitlichen Verlaufs der Residuallast, zusätzlich zur räumlichen Betrachtung, ermöglicht es, Muster und Auffälligkeiten im Zusammenspiel von Verbrauchern und Erzeugern zu erkennen. Abbildung 6-17 zeigt exemplarisch drei Momentaufnahmen der Residuallastverteilung für einen Tag im Sommer und einen im Winter. Tendenziell sind die Residuallasten im Winter höher, was darauf zurückzuführen ist, dass die Menschen sich vermehrt zu Hause aufhalten sowie die Beleuchtung länger eingeschaltet ist. Dennoch treten über das gesamte Jahr verteilt Tage mit negativer Residuallast auf und beschränken sich nicht nur auf den Sommer. Das ist auf die deutlich höhere produzierte Leistung von Wind im Gegensatz zu PV zurückzuführen, welche mit $\sim 4\,000$ GWh ca. vier Mal höher liegt.

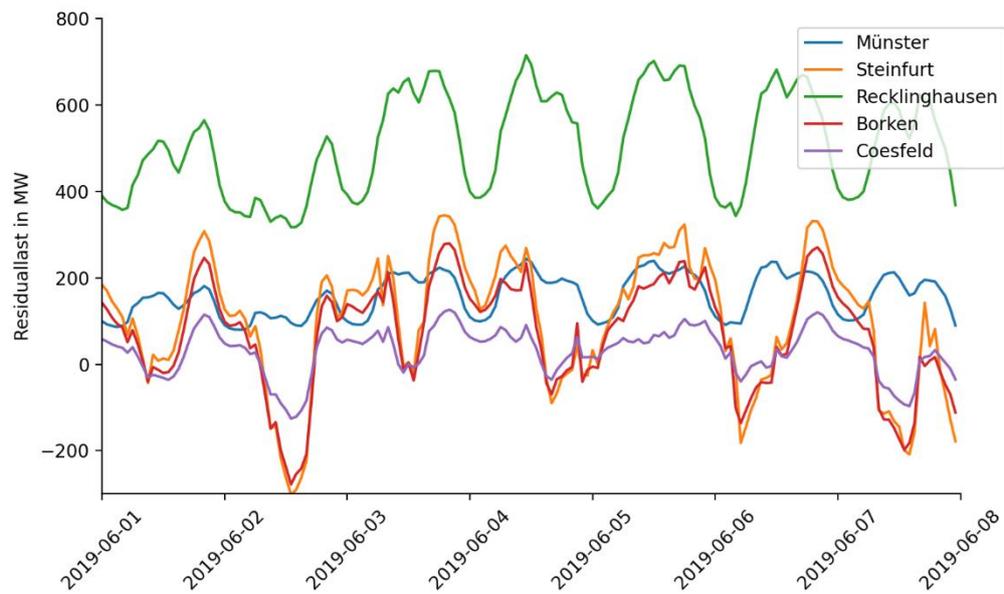


Abbildung 6-18: Zeitlich aufgelöster Verlauf der Residuallast für fünf Landkreise für eine Woche im Basisjahr

Weisen bestimmte Regionen konstant über das gesamte Jahr ein Defizit oder einen Überschuss an elektrischer Leistung auf, bieten sich diese Regionen unter Umständen als Standorte für den Ausbau erneuerbarer Energien oder die Installation von Elektrolyseuren an. In Abbildung 6-18 ist der zeitliche Verlauf der Residuallast beispielhaft für Münster, Steinfurt, Recklinghausen, Borken und Coesfeld für eine Woche im Juni des Basisjahres dargestellt. Es ist gut zu erkennen, dass im Kreis Recklinghausen, zu dem auch Marl mit der hohen industriellen Prägung zählt, durchgängig eine hohe Last vorliegt. Auch in Münster treten im betrachteten Zeitraum keine negativen Residuallasten auf. Im Basisjahr stellen beide Landkreise also reine Senken dar. In Borken, Coesfeld und Steinfurt treten hingegen wechselnd Lasten und Überschüsse auf. Bereits im Basisjahr sind also regionale Ausgleichspotenziale vorhanden. Durch den Ausbau von PV und Wind, aber auch durch die Transformation des Wärmesektors mit der Integration von mehr Wärmepumpen, ist zu erwarten, dass sich diese Ausgleichspotenziale zukünftig verändern. In Kapitel 8.3 werden diese Potenziale sowie die Auswirkung der Installation von Ausgleichstechnologien wie Elektrolyseuren näher untersucht.

7 Modellierung von regionalbezogenen Netzinfrastrukturen

Der im Rahmen des Projektes untersuchte zelluläre Ansatz (vgl. Kapitel 6) beschreibt Zellen als Hexagone, deren Form, Größe und Lage ohne Berücksichtigung realer Energieinfrastrukturen festgelegt wurden. Daher war das Ziel dieses Arbeitspaketes, das reale elektrische Netz in den beschriebenen zellulären Ansatz einzubeziehen. Dazu wurde geprüft, inwieweit die Übertragungs- und Verteilnetze bzw. die einzelnen Netzgruppen mit den Zellen übereinstimmen. Anschließend wurde ein Modell abgeleitet, das die Netzstrukturen mit den Zellen verknüpft und somit Untersuchungen des zellulären Ansatzes unter Berücksichtigung der elektrischen Netzinfrastruktur ermöglicht.

Bisherige Methoden zur Zuordnung von Regionen zu Übertragungsnetzknotten sind zur Lösung dieser Problemstellung nicht unmittelbar anwendbar. In der Regel muss eine Allokation durchgeführt werden, da relevante Verbrauchs- und Erzeugungsdaten z.B. auf Landkreisebene vorliegen, für die Netzberechnung allerdings konkrete Leistungsflusszeitreihen an den Netzverknüpfungspunkten benötigt werden und die Grenzen der Landkreise nicht mit den Netzgebietsgrenzen übereinstimmen. Dabei werden bei bisherigen Methoden die Verbrauchs- und Erzeugungseinrichtungen in der Regel einem einzelnen Übertragungsnetzknotten eindeutig zugeordnet. Es wird allerdings vernachlässigt, dass das untergeordnete Verteilnetz vermascht sein und mehrere Übertragungsnetzknotten

enthalten kann, sodass sich der Lastfluss einer einzelnen Anlage tatsächlich auf mehrere Knotenpunkte aufteilt. Dieser Sachverhalt kann für die Anwendung des zellulären Ansatzes problematisch sein, da sich einzelne Zellen nicht zwingend eindeutig zu genau einem Übertragungsknoten zuordnen lassen. Daher wurden die bisherigen Methoden zur Allokation weiterentwickelt, sodass auch Vermaschungen in den Verteilnetzen berücksichtigt werden.

Dazu wurden die Höchstspannungsebene (Übertragungsnetz, 380 kV und 220 kV) sowie die Hochspannungsebene (Verteilnetz, 110 kV) knotenscharf betrachtet. Die Leitungen des Verteilnetzes wurden berücksichtigt, um eine Verteilung der Erzeugungs- und Verbrauchseinrichtungen innerhalb des Verteilnetzes auf das Übertragungsnetz projizieren zu können. Das Ergebnis der Berechnung ist eine Einteilung der Landfläche von Deutschland in Polygone sowie eine Zuordnung dieser Polygone zu den Übertragungsknoten. Wird ein Polygon zu mehreren Übertragungsknoten zugeordnet, lässt sich die prozentuale Verteilung des Lastflusses zu den Knoten ermitteln. Die Lage und Zuordnung der Polygone wurden anschließend mit den Hexagonen aus dem zellulären Ansatz verglichen.

7.1 Datenquellen

Als Referenznetz wird der Datensatz zum deutschen Stromnetz aus dem Projekt open_eGo (DLR) verwendet. Dieser Datensatz wurde unter der *Open Data Commons Open Database License 1.0* unter *openenergy-platform.org* veröffentlicht und beinhaltet die benötigten Spannungsebenen 380 kV, 220 kV und 110 kV [63]. Da das Modell auf OpenStreetMap basiert, enthält der Datensatz hauptsächlich die Leitungen, Knoten und Transformatoren, die an der Oberfläche erkennbar sind. Diese sind mit einer geographischen Referenz sowie mit allen relevanten elektrotechnischen Eigenschaften beschrieben. Da Erdkabel nur teilweise im Datensatz enthalten sind, ist insbesondere das Hochspannungsnetz (110 kV) unvollständig abgebildet. Dennoch lässt sich das Modell zur Allokation von Erzeugungs- und Verbrauchsdaten zur Übertragungsebene verwenden, wenngleich konkrete Auswertungen der Netzbelastung im Verteilnetz nicht zulässig sind.

7.2 Methode zur Allokation unter Berücksichtigung des unterlagerten Verteilnetzes

Die Allokation erfolgt auf der Basis des elektrischen Netzmodells (Höchst- und Hochspannungsebene) in zwei Schritten (vgl. Abbildung 7-1). Im ersten Schritt wird eine Voronoi-Zerlegung des betrachteten Gebiets durchgeführt, bei dem die Verteilnetzknoten als Zentren berücksichtigt werden. Die entstehenden Polygone werden als Einzugsgebiete der Verteilnetzknoten angenommen. Im zweiten Schritt erfolgt eine vereinfachte Lastflussrechnung. Dabei wird das Netzmodell in der Art linearisiert, dass eine näherungsweise Berechnung der Lastverteilung unabhängig vom aktuellen Arbeitspunkt und somit vom tatsächlichen Lastfluss möglich ist.

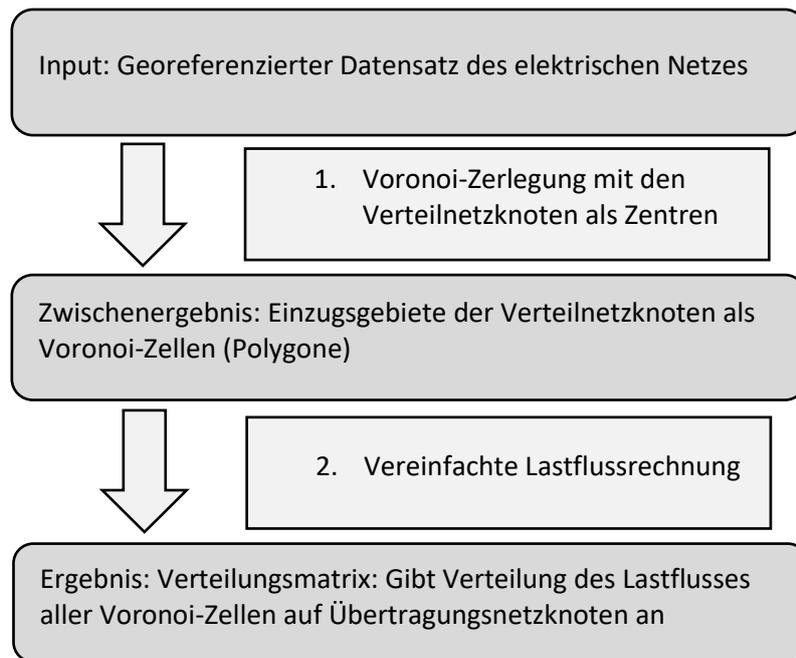


Abbildung 7-1: Ablauf der Methode zur Allokation unter Berücksichtigung des unterlagerten Verteilnetzes

Ziel der vereinfachten Lastflussrechnung ist eine Verteilungsmatrix, die die Verteilung des Lastflusses der einzelnen Voronoi-Zellen auf die Übertragungsnetzknoten angibt. Grundlage dieser Berechnung ist das Netzmodell des Hochspannungsnetzes. Damit eine vom tatsächlichen Netzzustand unabhängige Lastflussverteilung abgeleitet werden kann, werden die folgenden Annahmen getroffen:

1. Die Leistung, die an einem Netzknoten eingespeist oder entnommen wird, ist proportional zur Stromstärke. Änderungen der Spannung werden innerhalb des Netzes demnach als vernachlässigbar betrachtet.
2. Bei allen Leitungen ist das Verhältnis aus Wirk- und Blindwiderstand (R/X) gleich. Das hat zur Folge, dass bei der Berechnung der Admittanz- bzw. Verteilungsmatrix lediglich der Betrag der Leitwerte betrachtet werden muss.
3. Der Lastfluss im Übertragungsnetz hat keinen Einfluss auf die Lastflüsse im Verteilnetz. Dies wird bei der Berechnung berücksichtigt, indem an allen Übertragungsnetzknoten die Netzimpedanz in Richtung Übertragungsnetz vernachlässigt wird und somit an allen Übertragungsnetzknoten auf der Höchstspannungsseite das gleiche Potenzial anliegt.

Die Berechnung der Verteilungsmatrix erfolgt folgendermaßen:

Gegeben ist ein Hochspannungsnetz, das über n Netzknoten verfügt, welche über einen Transformator mit der Mittelspannungsebene (folgend Verteilnetzknoten) verbunden sind. Von den Verteilnetzknoten sind m Netzknoten unmittelbar mit der Übertragungsnetzebene verbunden (folgend Übertragungsnetzknoten). Sollte ein Übertragungsnetzknote tatsächlich über keinen direkten Anschluss an das Mittelspannungsnetz verfügen, so wird dieser Knoten dennoch als Verteilnetzknote betrachtet. Der Lastfluss in die Mittelspannungsebene ist an diesen Knoten dementsprechend dauerhaft gleich null.

Unter Anwendung des Überlagerungssatzes lässt sich der Stromfluss aus einem der Übertragungsnetzknoten als Summe aller (Teil-)Stromflüsse in die Verteilnetzknoten berechnen. Wenn die Transformatoren zum Mittelspannungsnetz und Übertragungsnetz an dem gleichen Netzknoten liegen, wird der Lastfluss des Mittelspannungstransformators zu 100 % dem entsprechenden Übertragungsnetzknoten zugeordnet. Für alle anderen Verteilnetzknoten kann das

Knotenpotenzialverfahren angewendet werden. Dazu werden unter Berücksichtigung der 3. Annahme (Vernachlässigung der Netzimpedanz in Richtung Übertragungsnetz) alle Übertragungsnetzknoten auf ein Potenzial gezogen und als Bezugspotenzial betrachtet. Es gilt

$$\underline{Y}_{VK,VK} \cdot \underline{\varphi}_{VK}^* = \underline{i}_{VK}^*$$

Wobei $\underline{Y}_{VK,VK}$ die Admittanzmatrix und $\underline{\varphi}_{VK}^*$ ein Vektor der Potenziale der Verteilnetzknoten bezogen auf das Bezugspotenzial sind. Der Vektor \underline{i}_{VK}^* enthält die Ströme in das Mittelspannungsnetz von allen $(n - m)$ Verteilnetzknoten, die nicht unmittelbar über einen Transformator in Richtung Übertragungsnetz verfügen. Dahingegen enthält der Vektor \underline{i}_{VK} alle n Ströme über die Mittelspannungstransformatoren:

$$\underline{i}_{VK} = \begin{pmatrix} \underline{i}_{VK}^* \\ i_{VK,\dot{U}K1} \\ \vdots \\ i_{VK,\dot{U}Kn} \end{pmatrix}$$

Mithilfe der Potenziale an den Verteilnetzknoten lassen sich die resultierenden Ströme aus dem Übertragungsnetz an den einzelnen Übertragungsnetzknoten ermitteln:

$$\begin{aligned} \underline{i}_{\dot{U}K}^* &= \underline{Y}_{\dot{U}K,VK} \cdot \underline{\varphi}_{VK}^* \\ &= \underbrace{\underline{Y}_{\dot{U}K,VK} \cdot (\underline{Y}_{VK,VK})^{-1}}_{\underline{V}_{\dot{U}K,VK}^*} \cdot \underline{i}_{VK}^* \end{aligned}$$

Dabei beschreiben die einzelnen Elemente von $\underline{Y}_{\dot{U}K,VK}$ die Koppeladmittanzen zwischen benachbarten Übertragungs- und Verteilnetzknoten. Die Matrix

$$\underline{V}_{\dot{U}K,VK}^* = \underline{Y}_{\dot{U}K,VK} \cdot (\underline{Y}_{VK,VK})^{-1}$$

ist nur ein Teil der gesuchten Verteilungsmatrix, da hier die Ströme der Mittelspannungstransformatoren, die direkt an einem Übertragungsnetzknoten liegen, noch nicht berücksichtigt sind. Diese Ströme müssen zu den jeweiligen Übertragungsnetzströmen addiert werden. Die vollständige $(m \times n)$ -Verteilungsmatrix $\underline{V}_{\dot{U}K,VK}$ ergibt sich demnach durch Anhängen einer Einheitsmatrix.

$$\begin{aligned} \underline{i}_{\dot{U}K} &= \left(\underline{V}_{\dot{U}K,VK}^* \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & 1 \end{pmatrix} \right) \cdot \begin{pmatrix} \underline{i}_{VK}^* \\ i_{VK,\dot{U}K1} \\ \vdots \\ i_{VK,\dot{U}Km} \end{pmatrix} \\ &= \underline{V}_{\dot{U}K,VK} \cdot \underline{i}_{VK} \\ \underline{V}_{\dot{U}K,VK} &= \left(\underline{Y}_{\dot{U}K,VK} \cdot (\underline{Y}_{VK,VK})^{-1} \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & 1 \end{pmatrix} \right) \end{aligned}$$

7.3 Berücksichtigung der elektrischen Netzinfrastruktur im zellulären Ansatz

Im Rahmen der Untersuchungen zum zellulären Ansatz sollen genau die Übertragungsnetzknoten innerhalb der Region DEA3 (Regierungsbezirk Münster) betrachtet werden, die über einen Transformator mit der Verteilnetzebene verbunden sind. Alle betrachteten Transformatoren sind in Abbildung 7-2 dargestellt. Verteilnetzknoten, welche keine direkte Verbindung zu einem der betrachteten Übertragungsnetzknoten aufweisen, werden nicht weiter berücksichtigt (z. B. im Westen der Region bei Bocholt).

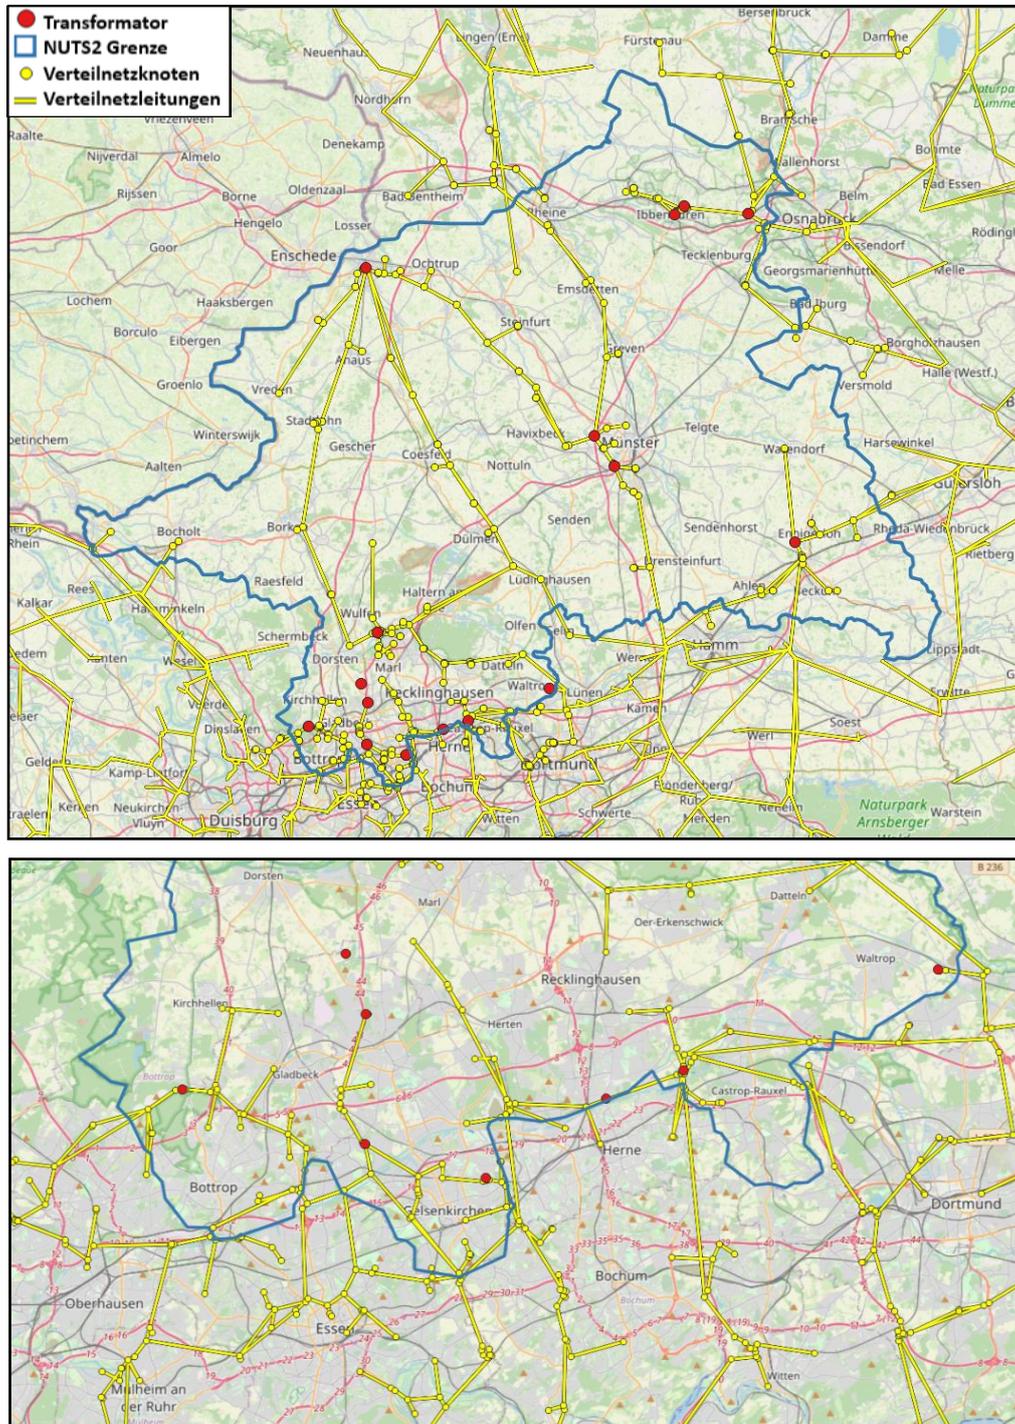


Abbildung 7-2: Betrachtete Transformatoren der Region DEA3 mit Verteilnetzknoten und Leitungen (oben)
Detailansicht der südlichen Grenzregion (unten)

einige Polygone gibt, dessen Lastfluss sich tendenziell gleichmäßig auf mehrere Transformatoren verteilt, sodass der Anteil am dominierenden Transformator unter 60 % oder sogar 50 % liegt.

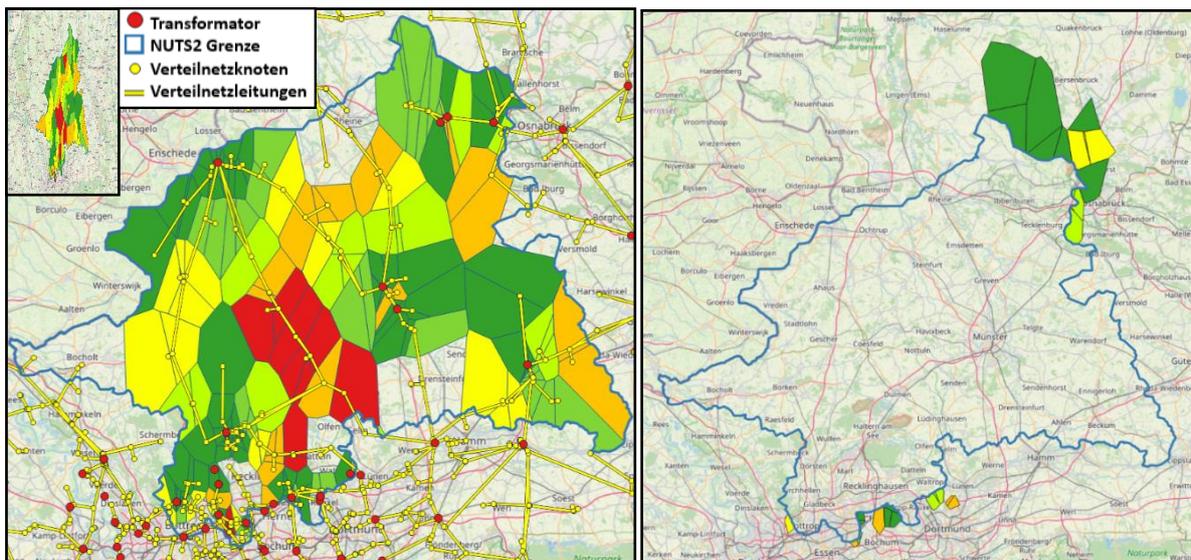


Abbildung 7-4: Heatmap der verbleibenden Polygone innerhalb der Region DEA3 mit Verteilnetz und Transformatoren (links) und Polygone außerhalb der Region, dessen dominierender Transformator innerhalb der Region liegt (rechts)

Bei der folgenden Integration der Netzinfrastruktur in den zellulären Ansatz wird dieser Sachverhalt vernachlässigt. Es wird also angenommen, dass sich die einzelnen Polygone vollständig dem dominierenden Transformator zuordnen lassen. Nach Zusammenfassung der Polygone der einzelnen Transformatoren ergeben sich die in Abbildung dargestellten Einzugsgebiete der betrachteten Transformatoren. Insbesondere im mittleren Teil der Region werden dadurch Fehler bei den Berechnungen erwartet, die bei anschließenden Untersuchungen zu berücksichtigen sind. Für weite Teile der Region liegt der Anteil am dominierenden Transformator allerdings bei über 70 %, zum Teil sogar über 90 %. Daher ist bei diesem Ansatz insgesamt von einer akzeptablen Näherung auszugehen.

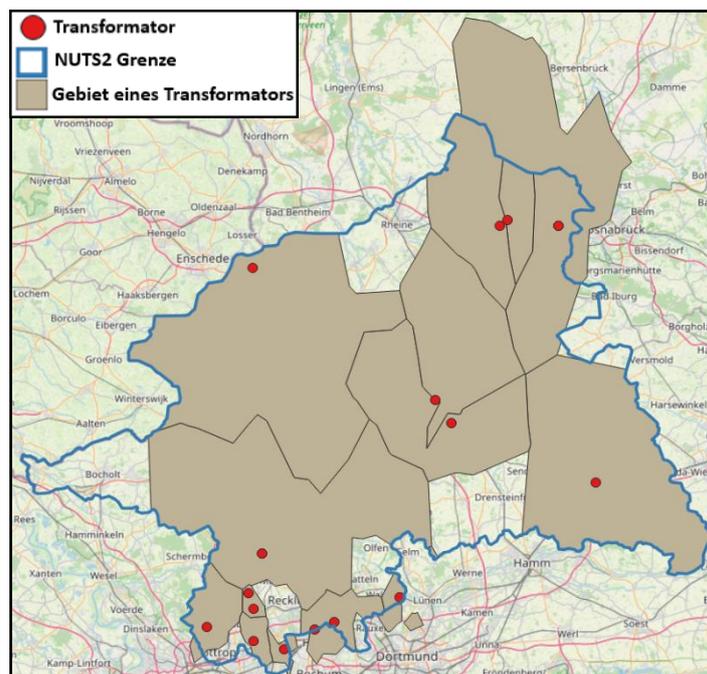


Abbildung 7-5: Verteilnetzknotten-Polygone zusammengefasst zu Polygonen (Einzugsgebiete) der betrachteten Transformatoren

8 Betrachtung von Strategien der Sektorenkopplung aus regionaler und infrastruktureller Perspektive

Im folgenden Abschnitt wird dargelegt, in welcher Form der überregionale Betrachtungsraum und die spezifischen Infrastrukturen, Anlagen und Bedarfsstrukturen miteinander interagieren können. Im Detail wird auf die Ausgestaltung der Szenarien eingegangen, welche sowohl die strukturelle Beschreibung und Verknüpfung der Bedarfsstrukturen und Anlagenverbände definieren, als auch die angenommene Regelungslogik und dem damit einhergehenden Informationsfluss. Ziel ist es, aufbauend auf der entwickelten Methodik der hexagonalen Energiezellen die Sektorenkopplung im regionalen Kontext abzubilden und unter Annahme zukünftiger Ausbaupfade mögliche Potenziale in der Dekarbonisierung im zentral und dezentral gesteuerten Gesamtsystem zu analysieren.

8.1 Szenariendefinition

Als Basisjahr für die Simulationen wird das Jahr 2019 gewählt, um den Einfluss der ab dem Jahr 2020 folgenden globalen Krisen auf den deutschen Energiemarkt nicht zu berücksichtigen. Für die betrachteten Szenarien wird das Szenario B des NEPs 2037 als Grundlage verwendet [57]. Die Verbraucherprofile für die Sektoren Wohnen, GHD und Strom und die Erzeugerprofile für Windkraft und Photovoltaik werden wie in Kapitel 0 beschrieben erstellt.

Neben den Windkraft- und Photovoltaikanlagen befinden sich noch weitere Erzeugungsanlagen innerhalb der Region Münster. Dazu gehören konventionelle Kraftwerke, wie Gas- und Kohlekraftwerke sowie weitere Erzeugungsanlagen auf Basis erneuerbarer Energien, wie Wasserkraftwerke und Biogasanlagen. Die Einspeisezeitreihen dieser Erzeugungsanlagen wurden in einer Marktsimulation über ganz Deutschland unter der Berücksichtigung von Speicherkraftwerken ermittelt. Dazu wurden mithilfe der mathematischen Optimierung Anlagenfahrpläne für alle Erzeugungsanlagen ermittelt, die in Summe zu den geringsten Gesamtstromerzeugungskosten führen. Es wurde zu jedem Zeitpunkt die maximal verfügbare Einspeiseleistung aller Erzeugungsanlagen in Deutschland (inkl. Windkraft und PV) berücksichtigt.

Für das Basisjahr 2019 wurden die installierte Leistung und die Verortung der Anlagen dem Marktstammdatenregister entnommen. Für die in diesem Projekt betrachteten Zukunftsszenarien wurden die Daten von 2019 entsprechend des Szenarios B des Netzentwicklungsplans 2037 skaliert. Im Anschluss wurden die Zeitreihen der Einzelanlagen für jeden Energieträger zu aggregierten Zeitreihen je Hexagon zusammengefasst.

Für das Zukunftsszenarium werden vier Varianten als Jahressimulation mit einer zeitlichen Auflösung von 1 h simuliert. Zuerst wird das Zukunftsszenario ohne Ausgleichstechnologien gerechnet. Die angenommene Technologieverteilung für die Wärmebereitstellung kann Kapitel 6.4.4 entnommen werden. Die angenommenen KWK-Anlagen zur Speisung der Fernwärmenetze werden so ausgelegt, dass sie ca. 8 000 Volllaststunden haben.

Zusätzlich wird die Technologieverteilung für zwei weitere Simulationen durch Elektrolyseure ergänzt. Angelehnt an die im Szenario B 2037 installierte Leistung von 26 GW und dem im Kapitel 6.4.4 verwendeten Faktor zum Herunterrechnen des deutschlandweiten Verbrauchs auf die Region Münster, wird aufgerundet eine installierte Elektrolyseurleistung von 1 GW in der betrachteten Region, aufgeteilt auf vier Standorte, angenommen. Bei der Verortung der Elektrolyseure wird darauf geachtet, dass eine Gastransportleitung in der Nähe ist und sie in Hexagonen mit einem bilanziellen Überschuss an regenerativ erzeugter Energie platziert werden (siehe Abbildung 8-1 und im Vergleich für den bilanziellen Überschuss der Hexagone Abbildung 8-8). Die beiden Simulationen unterscheiden sich bezüglich der Regelungsstrategien der Elektrolyseure.

Wie in Kapitel 5.3 beschrieben, werden die Elektrolyseure einmal über ein deutschlandweites und das andere Mal über ein lokales Regelungssignal gesteuert.

Bei der vierten Simulation werden zusätzlich zu den Elektrolyseuren mit der Regelungsstrategie, die sich am deutschlandweiten Stromüberschuss orientiert, Speicherbatterien für Photovoltaikanlagen verwendet. Für die in Münster installierte Leistung wird, analog zum Vorgehen bei den Elektrolyseuren, eine Gesamtleistung von 1,8 GW angenommen. Die Batterien werden nach dem Strombedarf geregelt, wobei der Strombedarf der Industrie ausgenommen wird. Die Batterien laden demnach, wenn es einen Überschuss an Photovoltaikstrom im Vergleich zum Strombedarf der übrigen Sektoren gibt und entladen entsprechend bei einer Unterdeckung des Strombedarfs.

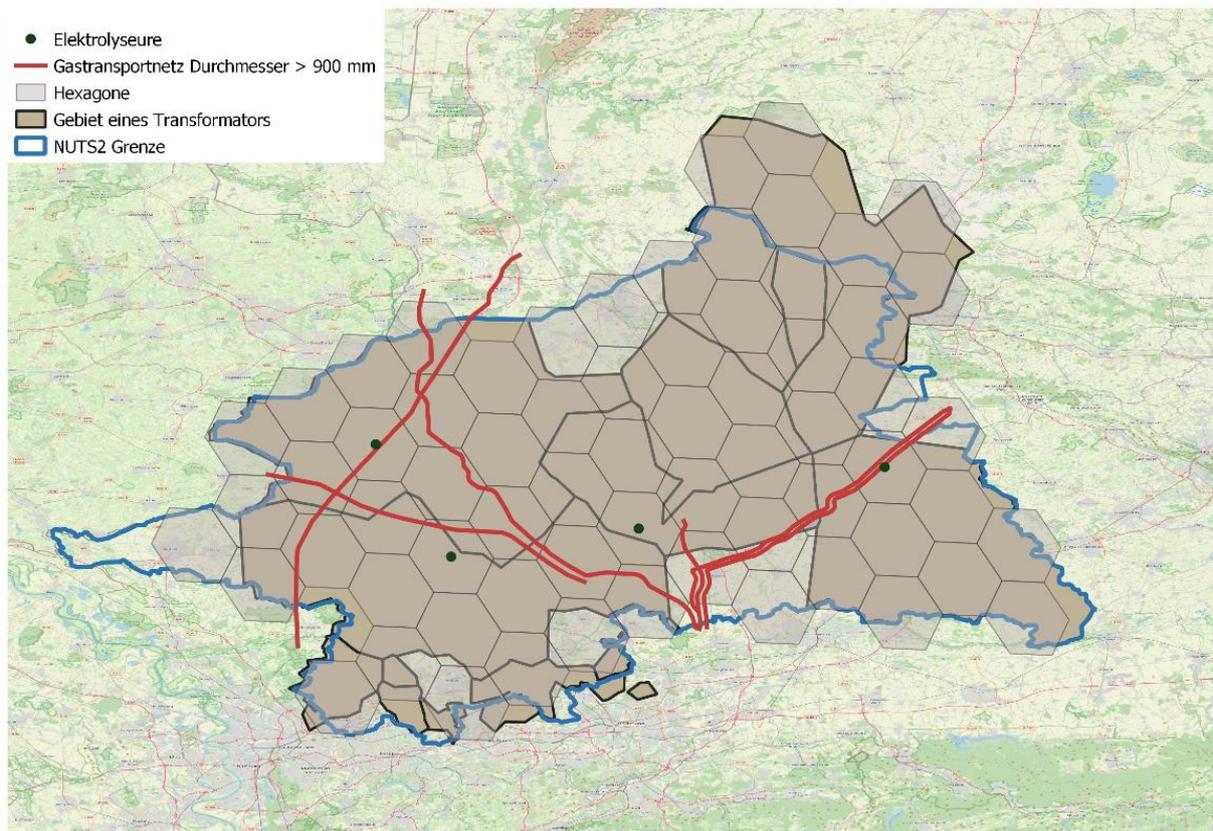


Abbildung 8-1: Verortung der Elektrolyseure im Szenariojahr.

8.2 Aufbau des Gesamtmodells

Das Grundmodell wird, wie in Kapitel 5.3 beschrieben, mit der eigens entwickelten Python-Bibliothek erzeugt (siehe Abbildung 8-2). Die Zellen und Knotenpunkte sind in dem Grundmodell bereits miteinander verbunden. Ergänzt werden müssen Modelle, die das Strom- und Gastransportnetz abbilden.

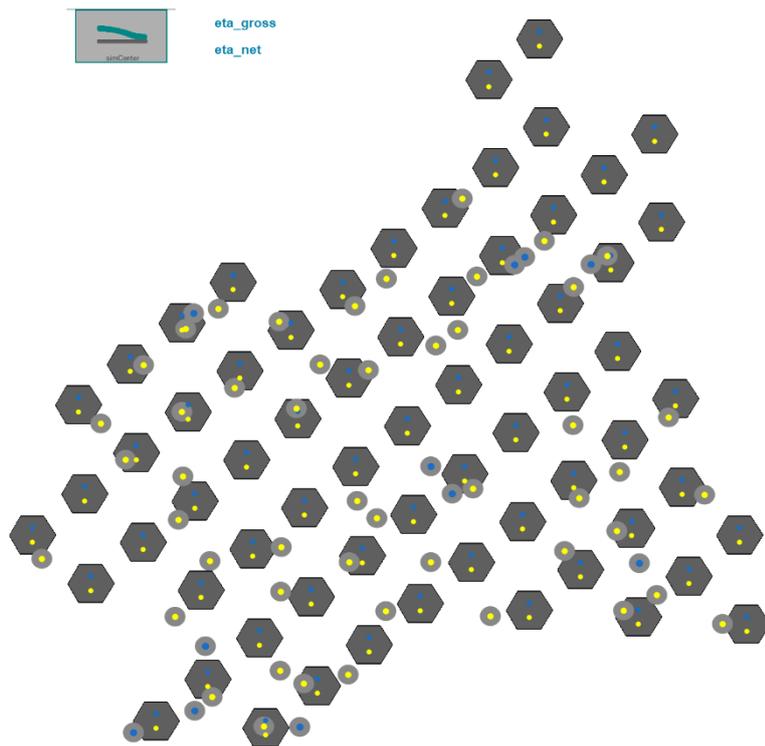


Abbildung 8-2: Grundmodell des Regierungsbezirks Münster.

Für die Zuordnung der Hexagone zu den Ausspeisepunkten des Gastransportnetzes wird, ähnlich zu dem Verfahren, wie für die Stromnetze in Kapitel 7 beschrieben, ein zweistufiges Voronoi-Verfahren angewendet. Dadurch soll der Fehler, der bei diesem Ansatz entsteht, verringert werden.

Im ersten Schritt wird die Anzahl der Ausspeisepunkte in jedem Hexagon, in dem mehr als ein Ausspeisepunkt liegt, auf eins reduziert, da für jedes Hexagon eine eindeutige Zuordnung zu einem Ausspeisepunkt möglich sein soll und innerhalb des Hexagons keine räumliche Auflösung berücksichtigt wird. Durch ein Voronoi-Verfahren wird jedem Hexagon ein Ausspeisepunkt zugeordnet. In Modelica soll nur die Topologie der Hauptgasleitungen, die große Durchmesser aufweisen, abgebildet werden (siehe Abbildung 8-3). Dafür wird im nächsten Schritt bei den ausgewählten Leitungen je Leitungsabschnitt vereinfacht ein Ausspeisepunkt angenommen und für diese erneut ein Voronoi-Diagramm erstellt. Durch Nachbearbeitung ergibt sich die in 8.3 dargestellte Zuordnung der Ausspeisepunkte aus dem Gastransportnetz zu den Hauptleitungen. Die Nachbearbeitung erfolgt auf Basis der Leitungen mit geringerem Durchmesser, d.h. wenn aufgrund des Verlaufs der untergeordneten Gasleitungen ersichtlich ist, dass ein Hexagon hauptsächlich durch eine andere als die zugeordnete Hauptleitung versorgt wird, wird die Zuordnung dementsprechend angepasst. Gemäß dem Verlauf der Hauptleitungen werden die untergeordneten Ausspeisepunkte im Modelica-Modell miteinander verbunden.



Abbildung 8-3: Verwendete Versorgungsgebiete der Ausspeisepunkte aus dem Gastransportnetz und Verlauf der Leitungen mit einem Durchmesser größer 900 mm des Gastransportnetzes in der betrachteten Region.

Die Abbildung der elektrischen Infrastruktur erfolgt bezüglich des Transportnetzes innerhalb der Region Münster knotenscharf. Beide Transportnetzebenen (220 kV und 380 kV) werden durch jeweils ein Netzmodell dargestellt und sind über Transformatoren miteinander verbunden. Dabei werden sowohl die Leitungen zwischen den Netzknoten als auch die Transformatoren zwischen der Transport- und Verteilnetzebenen detailliert abgebildet. Alle Leitungen, die die Grenzen der Region Münster überschreiten, sind an vereinfachte Netzmodelle des umliegenden europäischen Verbundnetzes der jeweiligen Spannungsebene angeschlossen. Die Netzkurzschlussleistung der vereinfachten Netzmodelle beträgt in Anlehnung an [64] 24 GVA (220 kV) bzw. 65 GVA (380 kV).

8.3 Ergebnisse und Auswertung

Die folgenden Betrachtungen beziehen sich jeweils auf die betrachteten Strom- und Gasnetzgebiete. Dadurch, dass diese jeweils nicht das gesamte Betrachtungsgebiet abdecken, ergeben sich leichte Abweichungen zu den Werten in Kapitel 0.

Vergleich der Szenarien ohne Ausgleichstechnologien

Im Basisszenario, angelehnt an das Jahr 2019, wird der größere Teil des Stroms noch konventionell erzeugt. In Abbildung 8-4 ist der geglättete Jahresverlauf des Strombedarfs und der Erzeugung auf Verteilnetzebene dargestellt. Der regenerative Anteil der Stromerzeugung übersteigt in der Abbildung den konventionellen, da größere konventionelle Anlagen direkt in das Übertragungsnetz einspeisen und damit nicht in die Darstellung mit eingehen. Der regenerativ erzeugte Strom kann zu keinem Zeitpunkt den Strombedarf der Region vollständig decken.

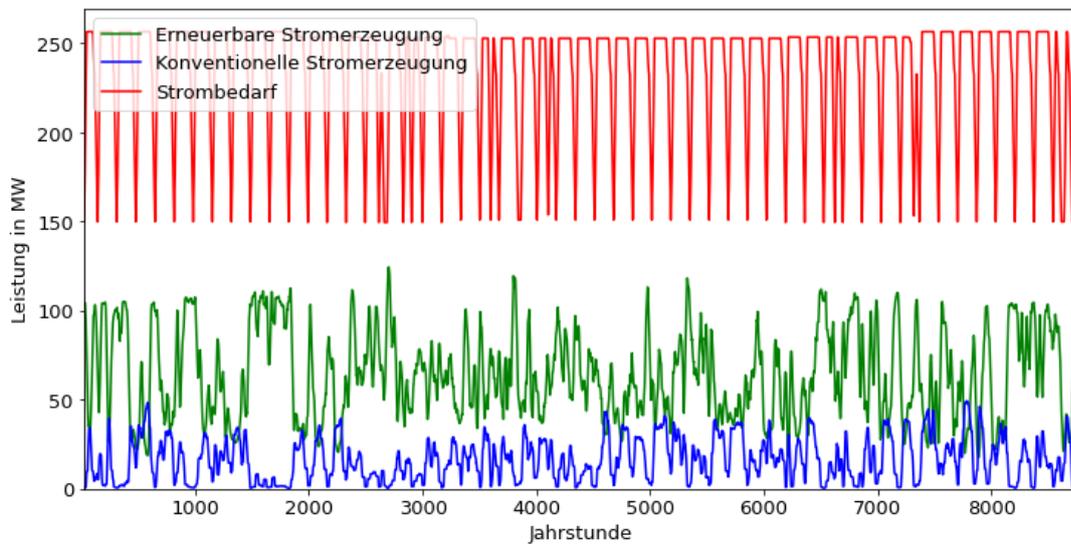


Abbildung 8-4: Gleitender Durchschnitt (Fenstergröße 24 h) des Strombedarfs und der Stromerzeugung auf Verteilnetzebene im Basisjahr, basierend auf 2019.

Im Vergleich dazu kann im Szenariojahr angelehnt an 2037 ein großer Teil des Strombedarfs durch regenerativ erzeugten Strom gedeckt werden (siehe Abbildung 8-5). Die erneuerbare Stromerzeugung in der Region übersteigt zeitweise immer wieder den Strombedarf. Auch ist eine leichte Saisonalität des Strombedarfs durch den Ausbau der Wärmepumpen zu sehen, d. h. während der Heizperiode ist der Strombedarf erhöht. Dadurch, dass die KWK-Anlagen so ausgelegt wurden, dass sie die Wärmegrundlast decken, liefern sie auch eine konstante elektrische Leistung.

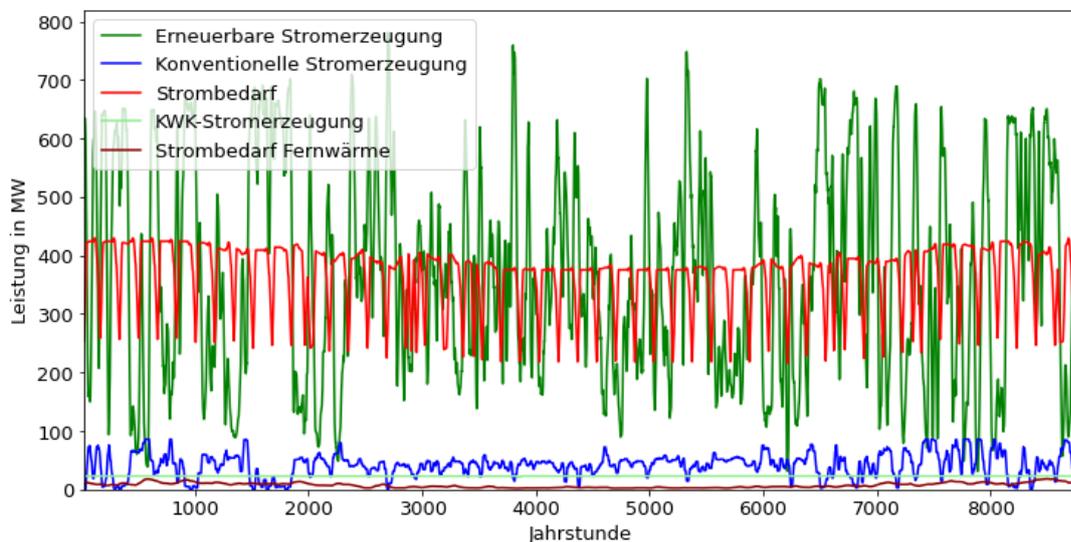


Abbildung 8-5: Gleitender Durchschnitt (Fenstergröße 24 h) des Strombedarfs und der Stromerzeugung im Szenariojahr, basierend auf 2037.

In Abbildung 8-6/Abbildung 8-9 ist der Strombedarf und die Stromerzeugung der ersten sieben Tage des Februars der beiden simulierten Jahre im Vergleich dargestellt. Der Samstag und Sonntag sind anhand des geringeren Strombedarfs zu erkennen (02. und 03.02.). Im Szenariojahr ist in diesem Zeitraum eine Über- und Unterdeckung des Strombedarfs durch erneuerbare Stromerzeugung in der Region zu sehen.

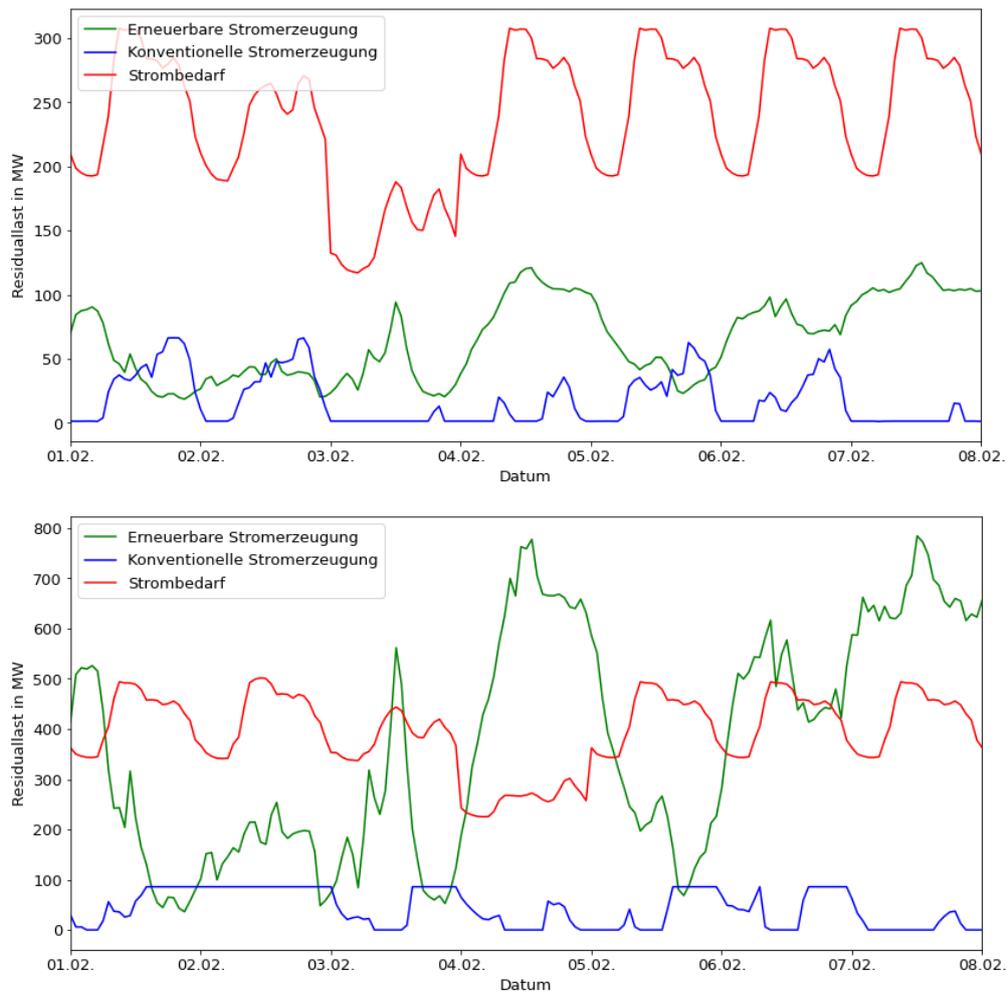


Abbildung 8-6: Stromerzeugung und Strombedarfe der betrachteten Region an den ersten sieben Februartagen; oben: Basisjahr; unten: Szenariojahr.

In Abbildung 8-7 und Abbildung 8-8 ist die Jahresenergiebilanz bezogen auf den Strombedarf und die regenerative Stromerzeugung für die Energiezellen für das Basisjahr und das Szenariojahr dargestellt. Eine positive Jahresenergiebilanz entspricht dabei einem Bedarfsüberschuss und eine negative Bilanz einem Erzeugungsüberschuss. Insgesamt zeigt sich eine Entwicklung von mehr Zellen mit Bedarfsüberschuss zu mehr Zellen mit überschüssiger Erzeugung. Auch die Anzahl der Zellen der mittleren Kategorie, die über das Jahr gesehen fast eine ausgeglichene Bilanz haben, nimmt ab. Gerade die Zellen, die einen sehr großen Bedarfsüberschuss haben, behalten diesen jedoch bei.

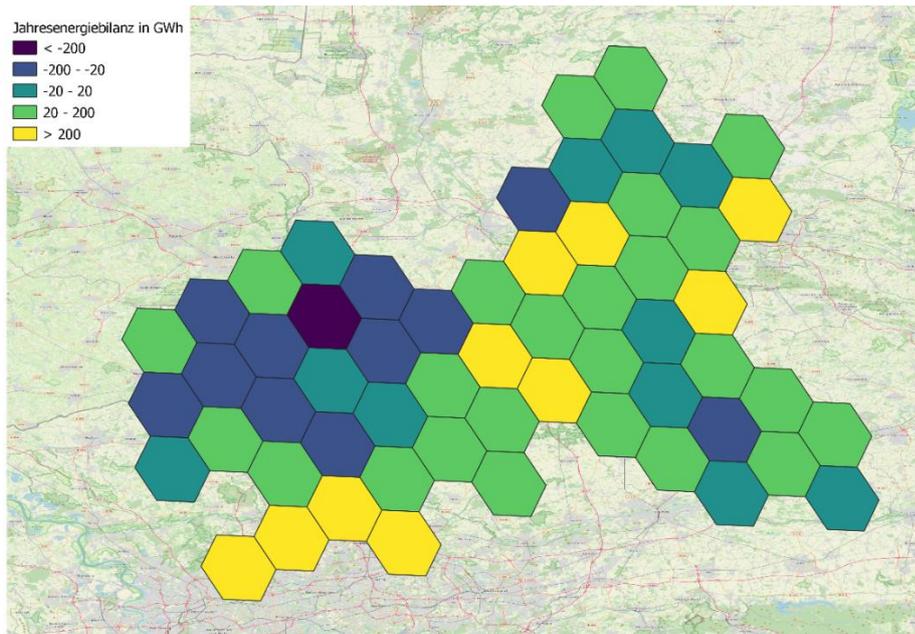


Abbildung 8-7: Jahresenergiebilanz der Energiezellen für das Basisjahr ohne konventionelle Stromerzeugung.

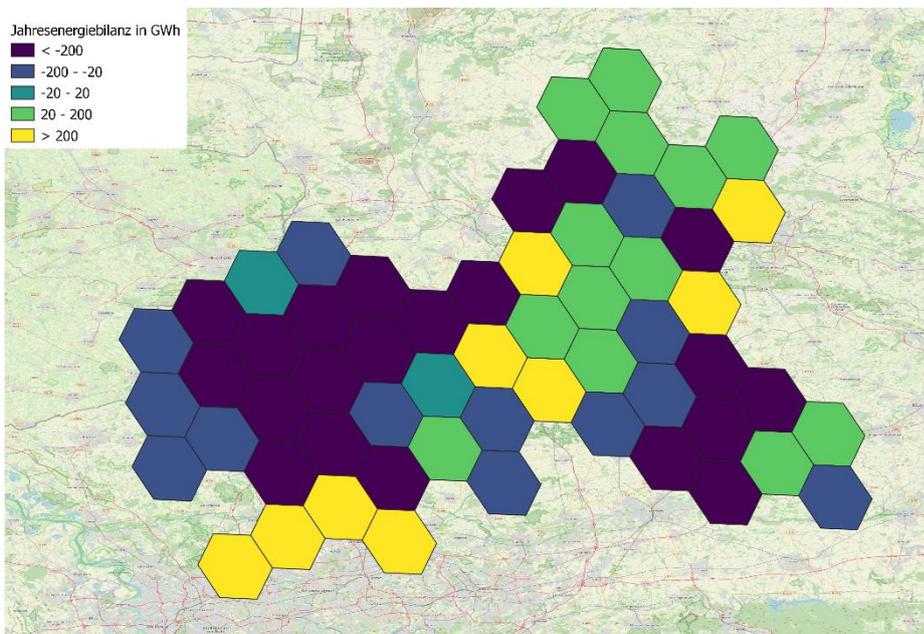


Abbildung 8-8: Jahresenergiebilanz der Energiezellen für das Szenariojahr ohne konventionelle Stromerzeugung.

Elektrolyseure

Beim Vergleich der beiden Regelungsstrategien für die Elektrolyseure ergibt sich für das deutschlandweite Regelungssignal eine Volllaststundenzahl der Elektrolyseure von 2 717 h und bei dem lokalen Regelungssignal von 3 645 h. Beide Regelungsstrategien haben damit zu einer Anzahl von Volllaststunden geführt, die wirtschaftlich sein kann, was jedoch stark von Rahmenbedingungen wie Wasserstoffpreisen und Investitionskosten abhängt, die im Rahmen dieses Projektes nicht mitbetrachtet wurden. Bei der Regelung mit dem lokalen Signal wird beispielsweise nicht sichergestellt, dass der Strom beim Betrieb günstig genug ist, um einen wirtschaftlichen Betrieb zu garantieren. In Abbildung 8-9 ist die Residuallast der Region mit und ohne Elektrolyseure dargestellt. Am 07.08. bei dem ersten dargestellten Tal (siehe erste graue Markierung) durch Stromüberschuss ist zu sehen, dass die lokale Regelung das Tal abflacht, während die deutschlandweite Regelung nur

ca. während der ersten Hälfte des Tals den Stromüberschuss reduziert und für den Rest der Zeit die Elektrolyseure wieder ausschaltet. Andersherum verstärkt die deutschlandweite Regelung der Elektrolyseure am 09.08. eine Lastspitze (siehe zweite graue Markierung), da deutschlandweit, aber nicht lokal gesehen ein Stromüberschuss herrscht.

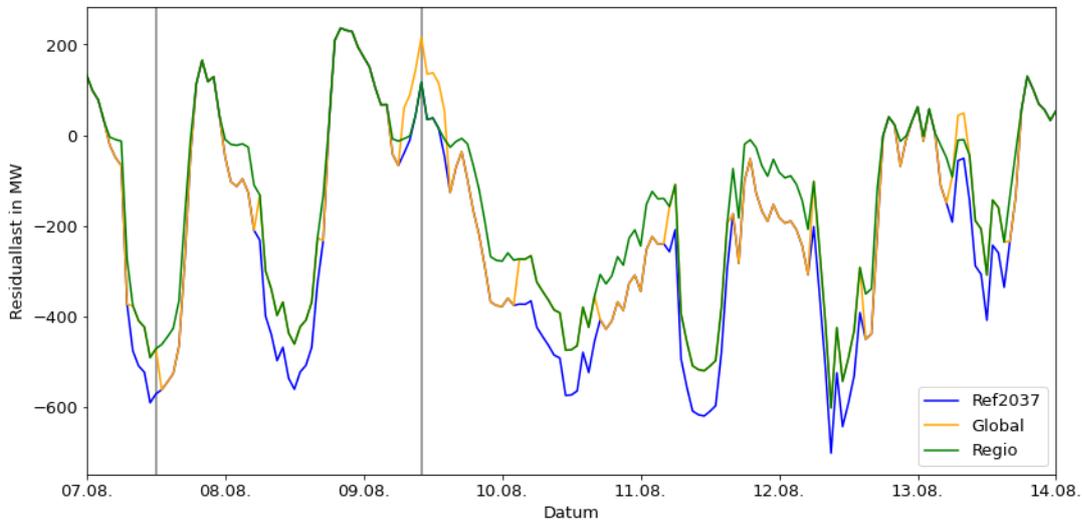


Abbildung 8-9: Verlauf der Residuallast an sieben Tagen im August für die verschiedenen Regelungsstrategien der Elektrolyseure im Vergleich.

Vergleich der Zukunftsszenarien

Werden die Jahresdauerlinien aller Zukunftsszenarien miteinander verglichen (siehe Abbildung 8-10), ist zu sehen, dass die Stromüberproduktion in jedem Szenario mit Ausgleichstechnologien reduziert wird. Die Elektrolyseure, die diese Reduktion explizit als Ziel haben, erreichen die deutlichste Reduktion von ca. 34 %. Im Vergleich dazu reduziert die deutschlandweite Regelung den Überschuss um ca. 23 %. Die zusätzlich zur deutschlandweiten Regelung eingesetzten Batterien leisten zu den Zeiten des sehr hohen Überschusses einen kleinen Beitrag, sodass insgesamt eine Reduktion von ca. 27 % erreicht wird.

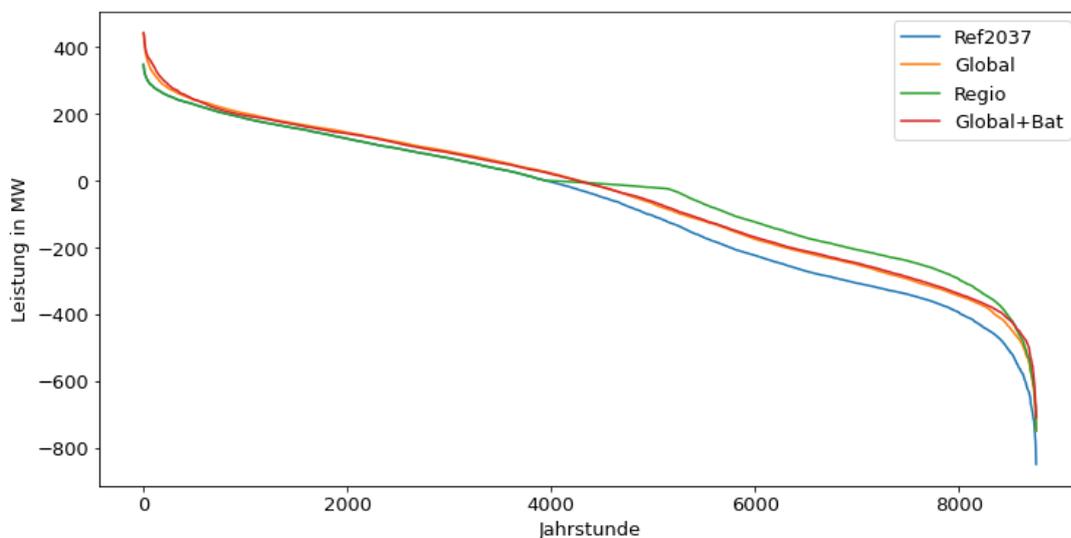


Abbildung 8-10: Vergleich der geordneten Jahresdauerlinie für die Zukunftsszenarien.

Wie sich die Lastflüsse auf die einzelnen Transformatoren des Übertragungsnetzes aufteilen, zeigt Abbildung 8-11. Für jedes Szenario und jeden Transformator ist jeweils die Jahresenergiebilanz aufgetragen.

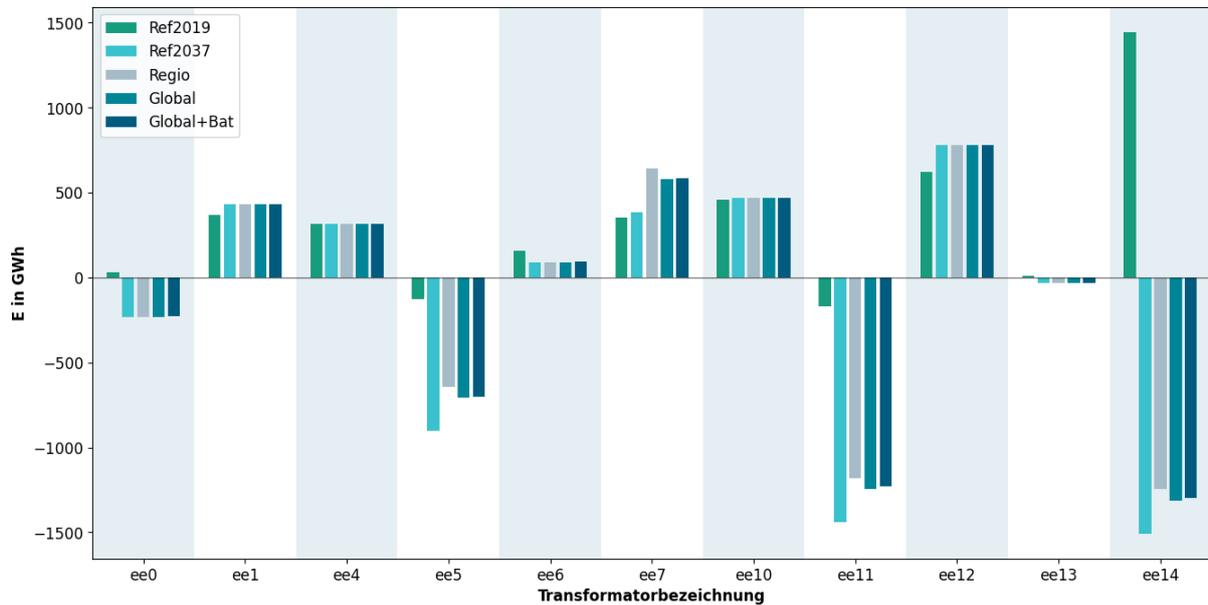


Abbildung 8-11: Residualenergie über ein Jahr je Transformator

Im Vergleich zum Basisjahr 2019 ist in einigen Netzgebieten eine deutliche Verschiebung hin zu einer Überdeckung der Einspeisung zu erkennen. Auffällig verhalten sich hier die Transformatoren ee5, ee11 und insbesondere ee14. Bei diesen Transformatoren handelt es sich um flächenmäßig sehr große Netzgebiete, in denen ein besonders großes Ausbaupotenzial für Wind- und PV-Anlagen besteht.

In den untersuchten Szenarien mit Ausgleichstechnologien wurden genau in diesen Netzgebieten Elektrolyseure platziert. Zusätzlich wurde ein weiterer Elektrolyseur dem Netzgebiet hinter Transformator ee7 zugeordnet. Hier ist zu erkennen, wie die Residualenergie in der Jahresbilanz durch den Elektrolyseur ansteigt. Im *Regio*-Szenario ist die Energiebilanz wie zu erwarten größer, da die Elektrolyseure im Vergleich zum *Global*- und *Global+Bat*-Szenario längere Betriebszeiten aufweisen.

Inwieweit die Transformatorbelastung durch die Betriebsweise der Ausgleichstechnologien reduziert oder erhöht wird, kann mithilfe von Abbildung 8-12 näher betrachtet werden.

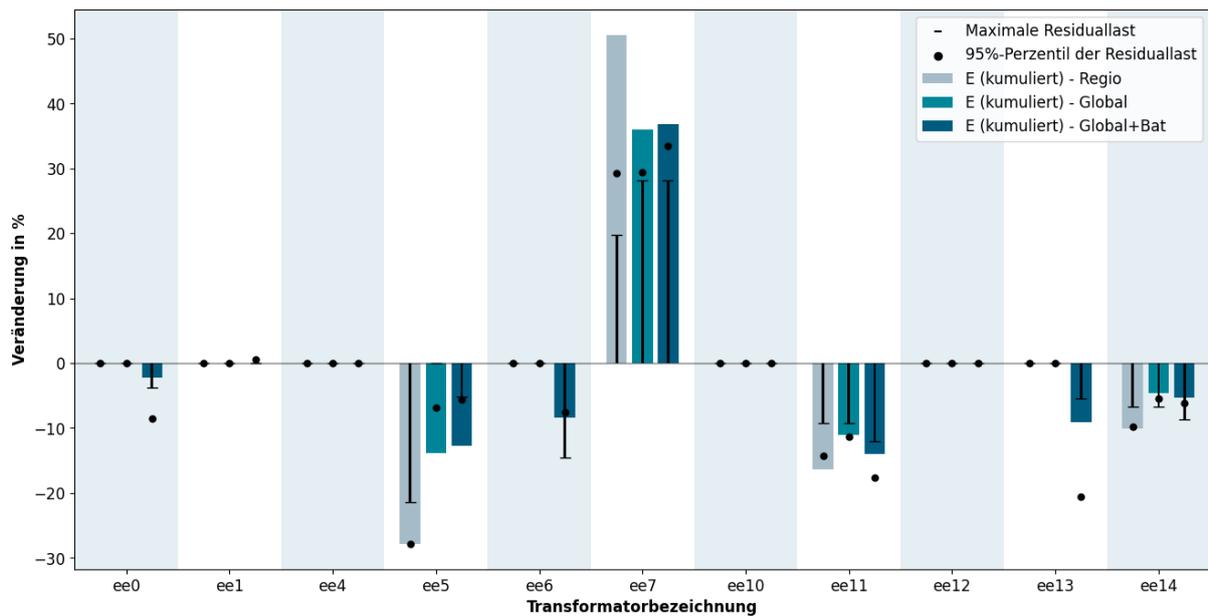


Abbildung 8-12: Relative Änderung des Maximums bzw. des 95%-Perzentils der Residuallast sowie der insgesamt übertragene Energiemenge

Dargestellt ist hier die relative Änderung der Residuallast im Vergleich zum Referenzszenario (2037). Die einzelnen Balken geben die kumulierte Energiemenge an, die der Transformator innerhalb eines Jahres überträgt. Zur Bewertung der Transformatorbelastung sind allerdings die auslegungsrelevanten Situationen - hier repräsentiert durch die Maxima und 95%-Perzentile der Residuallast - von größerer Bedeutung.

Eine Änderung der Transformatorbelastung ergibt sich - wie zu erwarten - nur an den Transformatoren, an denen sich Ausgleichstechnologien befinden: In Bezug auf den Einsatz von Elektrolyseuren (*Regio* und *Global*) sind dies die Transformatoren *ee5*, *ee7*, *ee11* und *ee14*. Hier ist zu erkennen, dass die Belastung, gemessen anhand der 95%-Perzentile, im *Regio*-Szenario um 0 bis 21 Prozentpunkte geringer ausfällt. Im lastdominierendem Netzgebiet (*ee7*) wird der Transformator in beiden Szenarien trotz der erhöhten Nutzungsdauer der Elektrolyseure im *Regio*-Szenario etwa gleich stark belastet.

Ein Vergleich der Szenarien *Global* und *Global+Bat* zeigt, dass sich der PV-Batteriespeicherbetrieb tendenziell positiv auf die Transformatorbelastung auswirkt. Dies gilt allerdings nicht für alle Transformatoren, sodass hier keine eindeutige Regelmäßigkeit erkennbar ist.

9 Zusammenfassung und Ausblick

Die Zielstellung von Integranet II war die Bewertung des Einsatzes der Sektorenkopplung und die Untersuchung von Interaktionen zwischen verschiedenen Regionen.

Grundlegende Methode für die Untersuchungen war die dynamische Simulation mit der Modelica-Bibliothek TransiEnt. Neue Modellentwicklungen und -erweiterungen im Rahmen von Integranet II wurden im Gegensatz zum Vorgängerprojekt Integranet unmittelbar in die TransiEnt-Bibliothek eingefügt und darüber veröffentlicht. Um dies zu ermöglichen, wurde gemeinsam mit Fraunhofer UMSICHT, dem GWI, der XRG Simulation GmbH und den drei an der Entwicklung der TransiEnt-Bibliothek beteiligten Instituten der TU Hamburg das TransiEnt-Konsortium gegründet. Die Mitglieder des TransiEnt-Konsortiums betreiben gemeinsam die Pflege der Modellbibliothek und treiben die Verbreitung der Bibliothek voran. Dazu gibt es regelmäßige Treffen innerhalb des Konsortiums, in denen über Neuentwicklungen abgestimmt und gemeinsame Aktivitäten geplant und abgestimmt werden, wie beispielsweise eine Verbesserung der Dokumentation der einzelnen Modelle. Dass auch außerhalb des Konsortiums das Interesse an der TransiEnt-Bibliothek hoch ist, zeigten zwei Workshops, die während der Projektlaufzeit durchgeführt wurden. Es wurden jeweils hohe Teilnehmendenzahlen erreicht und ein reges Interesse der Teilnehmenden an den Modellen und deren praktischer Anwendung wurde deutlich.

Im Rahmen des Projekts wurden verschiedene Neu- und Weiterentwicklungen von TransiEnt-Modellen getätigt. Eine davon ist die Integration eines Modells für das Laden von Elektrofahrzeugen in die Modellbibliothek. Da es das Ziel der Bibliothek ist, Modelle für die integrale Betrachtung von Energiesystemen bereitzustellen, war die Erweiterung der Modelle um die Schnittstellen zum Mobilitätssektor ein logischer nächster Schritt. Da realistische und plausible Lastprofile eine wichtige Grundlage für jede Modellrechnung sind, wurde zudem eine Datenbank konsistenter Haushaltslastprofile inkl. Elektromobilitäts-Fahrprofilen aufgebaut.

Die Modelle wurden in einer Fallstudie angewandt, in der modellbasiert untersucht wurde, wie sich die netzorientierte Steuerung von Ladestationen auf den Netz- und Anlagenbetrieb auswirkt (siehe Kapitel 3.3). Die Ergebnisse der Untersuchung zeigen, dass Elektrofahrzeuge zwar kritisch zur Belastung des elektrischen Netzes beitragen können, gleichzeitig aber auch einen zentralen Beitrag zu einem erfolgreichen Engpassmanagement leisten können. Da die Standzeiten und somit die Möglichkeit zum Laden im Vergleich zu den Abwesenheitszeiten bzw. zum Verbrauch verhältnismäßig groß sind, hat die Anwendung des Engpassmanagements nur einen geringen Einfluss auf den Ladezustand bzw. auf die Reichweite bei Fahrtantritt.

Ein weiterer Fokus des Projekts lag auf der überregionalen Betrachtung und den Wechselwirkungen und Ausgleichsmöglichkeiten zwischen unterschiedlich strukturierten Regionen. Zu dieser Untersuchung wurde ein zellulärer Ansatz gewählt. Um die Wechselwirkungen zwischen den Regionen modellbasiert mit Hilfe der TransiEnt-Bibliothek abbilden zu können und neben den dezentralen Einzelsystem-Regelungen auch zentrale Regelungen integrieren zu können, waren weitere Weiterentwicklungen der TransiEnt-Modelle nötig. Die umgesetzten Regelungsansätze werden in Kapitel 5 beschrieben. Zum einen wurden die bisher vorhandenen dezentralen Einzelsystemregelungen mit den *Poriented-*, *MaxSelfCons_connected-* sowie dem *MaxSelfCons_PriceLed_connected-* Controller um weitere Regelungsalgorithmen ergänzt, die im Modell *GridConstructor* zum Einsatz kommen. Zum anderen wurden Schnittstellen für eine zentrale Regelung geschaffen und diese über das Functional Mock-up-Interface implementiert. Hier kamen mit einem Model-Predictive-Control-Algorithmus und einem Reinforcement Learning zwei

verschiedene Optimierungsansätze zum Zuge. Die Funktionalität der unterschiedlichen Regelansätze wurde zudem in einer Fallstudie belegt und die Ergebnisse gegenübergestellt (Kapitel 5.2.3).

Im Rahmen des zellulären Ansatzes wird innerhalb jeder Zelle der lokale Energieverbrauch und die Energieerzeugung für die verschiedenen Sektoren und Energieträger bilanziert. Um vorhandene Daten den für den zellulären Ansatz verwendeten H3-Hexagonen zuzuordnen, wurden verschiedene Ansätze verwendet. Da Daten für die Standorte von kleineren PV-Anlagen lediglich auf Postleitzahlebene vorliegen, wurde eine Methode zur Lokalisierung der PV-Anlagen auf Basis künstlicher neuronaler Netze entwickelt, die auf hochaufgelösten Luftbildern trainiert wurde. Dazu wurde ein Datensatz aus Kalifornien und ein zweiter Datensatz des Bundesamts für Kartographie und Geodäsie mit Luftaufnahmen aus Deutschland verwendet. Das Vorgehen dazu ist in Kapitel 6.2 beschrieben. Insgesamt zeigte sich, dass das Modell in der Lage ist, auf verschiedenen Postleitzahlengebieten gute Ergebnisse zu liefern. Allerdings offenbarte es auch Schwächen, wie die teilweise Segmentierung ganzer landwirtschaftlicher Felder, die zu Überschätzungen führte. Diese Fehler konnten im Post-Processing korrigiert werden, indem große Segmentierungen mit Marktstammdaten und Landnutzungsdaten abgeglichen werden. Somit kann die Verteilung von Photovoltaikanlagen in Deutschland in hoher räumlicher Auflösung und guter Genauigkeit bestimmt werden.

Für die Demonstration des zellulären Ansatzes und die detaillierte Betrachtung der Ergebnisse wurde als Beispielregion der Regierungsbezirk Münster ausgewählt. Dieser eignet sich gut für die Anwendung der Methodik, da sowohl mehrere urbane Regionen mit einer hohen Bevölkerungsdichte, ein großer Industriestandort als auch ländlich geprägte Regionen innerhalb des Bezirks zu finden sind. Am Beispiel dieser Region wurde aufgezeigt, wie die Energieerzeugung und der Energieverbrauch den einzelnen Zellen zugeordnet und Lastprofile für jede Zelle erzeugt wurden (siehe Kapitel 6.3 und 6.4). Dabei wurden jeweils Last- und Erzeugungsprofile für das Jahr 2019 sowie für ein zukünftiges Szenario, bei dem sich an den Projektionen für das 2037 orientiert wurde, erstellt. Durch das Zusammenführen der Profile für Wind- und PV-Erzeugung sowie der Bedarfsprofile der Sektoren Haushalte, GHD und Industrie ließ sich eine örtlich und zeitlich aufgelöste zelluläre Residuallast ermitteln (Kapitel 6.5).

Da die Austauschmöglichkeiten zwischen den Zellen durch die Struktur der Übertragungs- und Verteilnetze bestimmt werden, wurde im nächsten Schritt das elektrische Netz in den zellulären Ansatz einbezogen. Dazu ist im ersten Schritt eine Allokation nötig, da relevante Verbrauchs- und Erzeugungsdaten in diesem Fall für einzelne Hexagone vorliegen, für die Netzberechnung allerdings konkrete Leistungsflusszeitreihen an den Netzverknüpfungspunkten benötigt werden und die Grenzen der Hexagone nicht mit den Netzgebietsgrenzen übereinstimmen. Dazu wurden bisherige Methoden zur Allokation weiterentwickelt, sodass auch Vermaschungen in den Verteilnetzen berücksichtigt werden (Kapitel 7.3).

Die einzelnen methodischen Schritte werden in einer abschließenden Simulation der Region Münster zusammengeführt und anhand dieser Beispielregion gezeigt, in welcher Form der überregionale Betrachtungsraum und die spezifischen Infrastrukturen, Anlagen und Bedarfsstrukturen miteinander interagieren können. Für die Simulation wird auf das TransiEnt-Modell *Superstructure* zurückgegriffen. Dazu wird das Grundmodell mit der dazu entwickelten Python-Bibliothek Gridelica erzeugt und um Modelle zur Abbildung der Strom- und Gastransportnetze ergänzt. Neben einer Simulation des Basisjahres wurden vier unterschiedliche Berechnungen (ohne Ausgleichstechnologien, Integration von Elektrolyseuren mit dezentraler Regelungsstrategie, Integration von Elektrolyseuren mit zentraler Regelung anhand des deutschlandweiten Stromüberschusses, Elektrolyseure + PV-Speicher mit zentraler Regelung) des betrachteten Szenariojahres durchgeführt.

Die Ergebnisse zeigen, dass im Jahr 2019 die regenerative Stromerzeugung innerhalb der Region zu keiner Zeit den Strombedarf decken kann. Im Szenariojahr übersteigt dagegen die erneuerbare

Stromerzeugung während des Jahres zeitweise immer wieder den Strombedarf, sodass ein großer Teil des Strombedarfs regenerativ gedeckt werden kann. So nimmt die Zahl der Zellen innerhalb der Region, die eine negative Jahresenergiebilanz mit einem Erzeugungsüberschuss aufweisen, bis zum betrachteten Szenariojahr deutlich zu. Gerade die Zellen, die einen sehr großen Bedarfsüberschuss haben, behalten diesen jedoch auch im betrachteten Zukunftsjahr bei.

Für die Elektrolyseure ergeben sich je nach Regelungsstrategie Volllaststundenzahlen zwischen 2 717 und 3 645 h und eine Reduktion der Stromüberproduktion von 23 % (Regelung anhand der deutschlandweiten Überschussstrommenge) bis 34 % (dezentrale Regelung). Gleichzeitig ist erkennbar, dass teilweise eine Entlastung der Transformatoren zu erkennen ist, die jedoch stark von den Rahmenbedingungen abhängen.

Was nicht aus den Ergebnissen ableitbar ist, ist die Wirtschaftlichkeit des Einsatzes der Ausgleichstechnologien, da keine Investitionskosten betrachtet und keine Kopplung mit einer Marktsimulation durchgeführt wurde. So konnte hier lediglich die Anwendung der Methode und die technische Machbarkeit der Ergebnisse gezeigt werden. Die wirtschaftliche Betrachtung müsste für einen konkreten Betrachtungsfall nachgelagert werden.

Insgesamt zeigt sich, dass eine integrale Betrachtung unter Verwendung geeigneter Regelungs- und Optimierungsalgorithmen unerlässlich ist, um die wachsende Komplexität und Dynamik des Energiesystems zu adressieren. Dazu sind geeignete Tools nötig, die die verschiedenen Sektoren übergreifend adressieren und die die traditionell einzeln betrachteten Sektoren Strom, Gas, (Fern-) Wärme und Mobilität als ein ganzheitliches System zu verstehen. Mit der TransiEnt-Bibliothek wurde bereits ein solches Simulationswerkzeug geschaffen. Um das optimale Design und den optimalen Betrieb unter Einbezug der vielfältigen Einflussfaktoren und Randbedingungen zu finden, müssen Simulationstools jedoch mit Optimierungstools verknüpft werden. Die Entwicklung entsprechender Toolchains für eine methodisch integrierte und holistische Systemplanung soll in entsprechenden Nachfolgeprojekten der Partner adressiert werden.

10 Literaturverzeichnis

- [1] „Clara-Library“. Zugriffen: 13. September 2023. [Online]. Verfügbar unter: <https://www.claralib.com/>
- [2] L. Andresen, P. Dubucq, R. Peniche Garcia, G. Ackermann, A. Kather, und G. Schmitz, „Status of the TransiEnt Library: Transient simulation of coupled energy networks with high share of renewable energy“, in *Proceedings of the 11th International Modelica Conference*, Versailles, Frankreich, Sep. 2015. doi: 10.3384/ecp15118695.
- [3] A. Senkel u. a., „Status of the TransiEnt Library: Transient Simulation of Complex Integrated Energy Systems“, in *Proceedings of 14th Modelica Conference 2021*, Linköping, Schweden, Sep. 2021. doi: 10.3384/ecp21181187.
- [4] J.-P. Heckel und C. Becker, „Advanced Modeling of Electric Components in Integrated Energy Systems with the TransiEnt Library“, in *Proceedings of the 13th International Modelica Conference*, Regensburg, Deutschland, März 2019. doi: 10.3384/ecp19157759.
- [5] J. Benthin, A. Heyer, P. Huisman, M. Djukow, A. Hagemeyer, und K. Görner, „Demand oriented Modelling of coupled Energy Grids“, in *Proceedings of the 13th International Modelica Conference*, Regensburg, Deutschland, März 2019. doi: 10.3384/ecp1915759.
- [6] J. Benthin u. a., „Integrierte Betrachtung von Strom-, Gas- und Wärmesystemen zur modellbasierten Optimierung des Energieausgleichs- und Transportbedarfs innerhalb der deutschen Energienetze“, *Gemeinsamer Abschlussbericht des Forschungsvorhabens IntegraNet*, 2020.

- [7] F. Kraftfahrt-Bundesamt, Hrsg., „Fahrzeugzulassungen (FZ): Neuzulassungen von Kraftfahrzeugen nach Umwelt-Merkmalen Jahr 2021“. Mai 2022.
- [8] M. Krail, D. Speth, T. Gnann, und M. Wietschel, „Langfristszenarien für die Transformation des Energiesystems in Deutschland: Treibhausgasneutrale Hauptszenarien - Modul Verkehr“. Fraunhofer ISI and Consentec GmbH, BMWK, 25. November 2021.
- [9] H. H. Stapelberg und K. Torp, „Energieprognose Deutschland 2018-2040“. ExxonMobil Central Europe Holding GmbH, März 2018.
- [10] J. Burchardt u. a., „Klimapfade 2.0: Ein Wirtschaftsprogramm für Klima und Zukunft“. The Boston Consulting Group, Oktober 2021.
- [11] D. Heinz, „Erstellung und Auswertung repräsentativer Mobilitäts- und Ladeprofile für Elektrofahrzeuge in Deutschland“. Karlsruhe, 2018. doi: 10.5445/IR/1000086372.
- [12] A. Heier, A. Hutterer, und A. Haber, „Anwendung der Lastgangrechnung am Beispiel der Elektromobilität“. Februar 2018. doi: 10.3217/978-3-85125-586-7.
- [13] G. Göhler, C. Schmaus, und A.-L. Klingler, „Netzbelastungen und Netzdienstleistungen durch Elektrofahrzeuge : Metastudie“. Universität Stuttgart, 2019. doi: 10.18419/opus-10607.
- [14] N. Pflugradt, P. Stenzel, L. Kotzur, und D. Stolten, „LoadProfileGenerator: An Agent-Based Behavior Simulation for Generating Residential Load Profiles“, *Journal of Open Source Software*, Bd. 7, Nr. 71, S. 3574, 2022, doi: 10.21105/joss.03574.
- [15] W. Dauth und P. Haller, „Berufliches Pendeln zwischen Wohn- und Arbeitsort: Klarer Trend zu längeren Pendeldistanzen: IAB-Kurzbericht, No. 10/2018“, Nr. 10/2018. in IAB-Kurzbericht. Nürnberg: Institut für Arbeitsmarkt- und Berufsforschung (IAB), 2018.
- [16] Statistisches Bundesamt, Hrsg., „Stromverbrauch der privaten Haushalte nach Haushaltsgrößenklassen“. September 2023. [Online]. Verfügbar unter: <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Umwelt/UGR/private-haushalte/Tabellen/stromverbrauch-haushalte.html>
- [17] TAEV 2012, *bundeseinheitliche Fassung: Technische Anschlussbedingungen für den Anschluss an öffentliche Versorgungsnetze mit Betriebsspannungen bis 1000 Volt, mit Erläuterungen der einschlägigen Vorschriften*. Wien: Österreichs E-Wirtschaft Akademie, 2012. [Online]. Verfügbar unter: <https://permalink.obvsg.at/AC09576530>
- [18] Das Kraftfahrt-Bundesamt, Hrsg., „Inländerfahrleistung: Entwicklungen der Fahrleistungen nach Fahrzeugarten seit 2016“. Juni 2021. [Online]. Verfügbar unter: https://www.kba.de/DE/Statistik/Kraftverkehr/VerkehrKilometer/vk_inlaenderfahrleistung/2020/2020_vk_kurzbericht.html
- [19] Statistisches Bundesamt, Hrsg., „Anschlussgrad sowie Wasserabgabe an Haushalte, gewerbliche und sonstige Abnehmer: Öffentliche Wasserversorgung in Deutschland von 1991 bis 2019“. Oktober 2021. [Online]. Verfügbar unter: <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Umwelt/Wasserwirtschaft/Tabellen/ww-01-wasserabgabe1991-2019.html>
- [20] M. Zhdanova, J. Urbansky, A. Hagemeyer, D. Zelle, I. Herrmann, und D. Höffner, „Local Power Grids at Risk – An Experimental and Simulation-based Analysis of Attacks on Vehicle-To-Grid Communication“, in *Proceedings of the 38th Annual Computer Security Applications Conference*, Austin TX USA: ACM, Dez. 2022, S. 42–55. doi: 10.1145/3564625.3568136.
- [21] G. Kerber, „Aufnahmefähigkeit von Niederspannungsverteilstellen für die Einspeisung aus Photovoltaikkleinanlagen“, PhD Thesis, Technische Universität München, 2011.
- [22] S. Krähenmann, A. Walter, S. Brienens, F. Imbery, und A. Matzarakis, „High-resolution grids of hourly meteorological variables for Germany“, *Theor Appl Climatol*, Bd. 131, Nr. 3–4, S. 899–926, Feb. 2018, doi: 10.1007/s00704-016-2003-7.
- [23] Statistisches Bundesamt, „Genesis-Online: Fortschreibung des Bevölkerungsstandes: Statistik:12411“. [Online]. Verfügbar unter: <https://www-genesis.destatis.de/genesis/online?sequenz=statistikTabellen&selectionname=12411#abreadcru mb>

- [24] Bundesnetzagentur, „Marktstammdatenregister“. [Online]. Verfügbar unter: <https://www.marktstammdatenregister.de/MaStR/>
- [25] „Ortsgenaue Testreferenzjahre von Deutschland für mittlere und extreme Witterungsverhältnisse“, DWD, Offenbach, Projektbericht, 2017. [Online]. Verfügbar unter: <https://www.bbsr.bund.de/BBSR/DE/forschung/programme/zb/Auftragsforschung/5EnergieKlimaBauen/2013/testreferenzjahre/try-projektbericht.pdf>
- [26] Bundesnetzagentur, „Bundesnetzagentur legt Regelungen zur Integration steuerbarer Verbrauchseinrichtungen fest“, Pressemitteilung. Zugegriffen: 11. Dezember 2023. [Online]. Verfügbar unter: https://www.bundesnetzagentur.de/SharedDocs/Pressemitteilungen/DE/2023/20231127_14a.html
- [27] „Digitalisierung-Flexibiltäetsmarkt-Nachtspeicherheizungen-wie-passt-das-zusammen.pdf“. Zugegriffen: 13. Dezember 2023. [Online]. Verfügbar unter: <https://www.ffe.de/wp-content/uploads/2020/12/Digitalisierung-Flexibiltäetsmarkt-Nachtspeicherheizungen-wie-passt-das-zusammen.pdf>
- [28] Dassault Systèmes, „FMI-Unterstützung – Dymola“, Functional Mock-up Interface. Zugegriffen: 18. Dezember 2023. [Online]. Verfügbar unter: <https://www.3ds.com/de/produkte-und-services/catia/produkte/dymola/fmi/>
- [29] C. Bode u. a., „Resilienz gekoppelter Energienetze mit hohem Anteil Erneuerbarer Energien - Abschlussbericht des Verbundvorhabens“, Hamburg, 2021. doi: 10.2314/KXP:1794036792.
- [30] Uber Technologies, „H3 Geospatial Indexing System“. 8. November 2023. [Online]. Verfügbar unter: <https://h3geo.org/docs/>
- [31] G. Görz, U. Schmid, und T. Braun, Hrsg., *Handbuch der Künstlichen Intelligenz*. Berlin, Boston: De Gruyter Oldenbourg, 2020. doi: 10.1515/9783110659948.
- [32] A. Halevy, P. Norvig, und F. Pereira, „The Unreasonable Effectiveness of Data“, *IEEE Intelligent Systems*, Bd. 24, Nr. 2, S. 8–12, 2009, doi: 10.1109/MIS.2009.36.
- [33] H. Aghdam und E. Heravi, *Guide to Convolutional Neural Networks: A Practical Application to Traffic-Sign Detection and Classification*. 2017. doi: 10.1007/978-3-319-57550-6.
- [34] I. Goodfellow, Y. Bengio, und A. Courville, *Deep Learning*. MIT Press, 2016. [Online]. Verfügbar unter: <http://www.deeplearningbook.org>
- [35] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems*, Second edition. in Covid-19 collection. Beijing Boston Farnham Sebastopol Tokyo: O’Reilly, 2019.
- [36] D. Kingma und J. Ba, „Adam: A Method for Stochastic Optimization“, *International Conference on Learning Representations*, Dez. 2014.
- [37] K. Mayer, Z. Wang, M.-L. Arlt, D. Neumann, und R. Rajagopal, „DeepSolar for Germany: A deep learning framework for PV system mapping from aerial imagery“, Sep. 2020, S. 1–6. doi: 10.1109/SEST48500.2020.9203258.
- [38] K. Simonyan und A. Zisserman, „Very Deep Convolutional Networks for Large-Scale Image Recognition“, *arXiv e-prints*, S. arXiv:1409.1556, Sep. 2014, doi: 10.48550/arXiv.1409.1556.
- [39] G. Huang, Z. Liu, L. van der Maaten, und K. Weinberger, „Densely Connected Convolutional Networks“, Juli 2017. doi: 10.1109/CVPR.2017.243.
- [40] O. Ronneberger, P. Fischer, und T. Brox, „U-Net: Convolutional Networks for Biomedical Image Segmentation“, in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, N. Navab, J. Hornegger, W. M. Wells, und A. F. Frangi, Hrsg., Cham: Springer International Publishing, 2015, S. 234–241.
- [41] T. Mujtaba und M. Wani, „Segmentation of Satellite Images of Solar Panels Using Fast Deep Learning Model“, März 2021.
- [42] Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh, und J. Liang, „UNet++: A Nested U-Net Architecture for Medical Image Segmentation“, *CoRR*, Bd. abs/1807.10165, 2018, [Online]. Verfügbar unter: <http://arxiv.org/abs/1807.10165>

- [43] K. Bradbury *u. a.*, „Distributed solar photovoltaic array location and extent dataset for remote sensing object identification“, *Scientific Data*, Bd. 3, Nr. 1, S. 160106, Dez. 2016, doi: 10.1038/sdata.2016.106.
- [44] „Geobasisdaten: GeoBasis-DE / BKG, Terms of use; http://sg.geodatenzentrum.de/web_public/nutzungsbedingungen.pdf“. 2022.
- [45] K. Wada, „Labelme: Image Polygonal Annoation with Python“. [Online]. Verfügbar unter: <https://github.com/wkentaro/labelme>
- [46] Z. A. Styczynski, M. Stötzer, und P. Lombardi, „Wandlung von Primärenergie in Nutzenergie“, 2014, S. 796–811. doi: 10.1007/978-3-642-38891-0_75.
- [47] J. Scheffler, „Bestimmung der maximal zulässigen Netzanschlussleistung photovoltaischer Energiewandlungsanlagen in Wohnsiedlungsgebieten“, Nov. 2002.
- [48] H. Ruf, G. Heilscher, F. Meier, O. Mayer, und M. Grottko, „Impact of Increasing Photovoltaic Energy Penetration on the Distribution Grid“, Sep. 2012. doi: 10.4229/27thEUPVSEC2012-6CV.3.23.
- [49] K. Mayer *u. a.*, „3D-PV-Locator: Large-scale detection of rooftop-mounted photovoltaic systems in 3D“, *Applied Energy*, Bd. 310, S. 118469, 2022, doi: <https://doi.org/10.1016/j.apenergy.2021.118469>.
- [50] J. Yu, Z. Wang, A. Majumdar, und R. Rajagopal, „DeepSolar: A Machine Learning Framework to Efficiently Construct a Solar Deployment Database in the United States“, *Joule*, Bd. 2, Nr. 12, S. 2605–2617, 2018, doi: <https://doi.org/10.1016/j.joule.2018.11.021>.
- [51] N. Darapaneni, A. Jagannathan, V. Natarajan, G. V. Swaminathan, S. Subramanian, und A. R. Paduri, „Semantic Segmentation of Solar PV Panels and Wind Turbines in Satellite Images Using U-Net“, in *2020 IEEE 15th International Conference on Industrial and Information Systems (ICIIS)*, 2020, S. 7–12. doi: 10.1109/ICIIS51140.2020.9342701.
- [52] H. Hersbach *u. a.*, „The ERA5 global reanalysis“, *Quart J Royal Meteorol Soc*, Bd. 146, Nr. 730, S. 1999–2049, Juli 2020, doi: 10.1002/qj.3803.
- [53] oemof developer group, „windpowerlib“. [Online]. Verfügbar unter: <https://github.com/wind-python/windpowerlib>
- [54] LANUV, „Solarkataster-Potentiale-FF-Photovoltaik_05500000_Muenster_EPSG25832_Geodatabase“. 4. April 2022. [Online]. Verfügbar unter: https://www.opengeodata.nrw.de/produkte/umwelt_klima/klima/solarkataster/ff_photovoltaik/
- [55] B. W. e.V., „Funktionsweise von Windenergieanlagen“, wind-energie. Zugegriffen: 13. Oktober 2023. [Online]. Verfügbar unter: <https://www.wind-energie.de/themen/anlagentechnik/funktionsweise/>
- [56] „Welchen Flächenbedarf haben Windenergieanlagen?“, Baden-Württemberg.de. Zugegriffen: 13. Oktober 2023. [Online]. Verfügbar unter: <https://um.baden-wuerttemberg.de/de/energie/erneuerbare-energien/windenergie/faq-windenergie/welchen-flaechenbedarf-haben-windenergieanlagen>
- [57] „NEP_2037_2045_V2023_2_Entwurf_Teil1_1.pdf“. Zugegriffen: 26. Oktober 2023. [Online]. Verfügbar unter: https://www.netzentwicklungsplan.de/sites/default/files/2023-07/NEP_2037_2045_V2023_2_Entwurf_Teil1_1.pdf
- [58] F. Gotzens *u. a.*, „DemandRegio - Harmonisierung und Entwicklung von Verfahren zur regionalen und zeitlichen Auflösung von Energienachfragen : Abschlussbericht“, 2020, doi: 10.34805/FFE-119-20.
- [59] Dr. Tim Drees (50Hertz Transmission GmbH), Thomas Dederichs (Amprion GmbH), Mario Meinecke (TenneT TSO GmbH), und Astrid Dolak (TransnetBW GmbH), „Szenariorahmen zum Netzentwicklungsplan Strom 2037 mit Ausblick 2045, Version 2023“. Januar 2022.
- [60] Prognos, Öko-Institut, und Wuppertal-Institut, „Klimaneutrales Deutschland 2045. Wie Deutschland seine Klimaziele schon vor 2050 erreichen kann, Studie im Auftrag von Stiftung

Klimaneutralität, Agora Energiewende und Agora Verkehrswende.“, 2021. Zugegriffen: 2. August 2023. [Online]. Verfügbar unter: https://static.agora-energiewende.de/fileadmin/Projekte/2021/2021_01_DE_KNDE2045/KNDE2045_Langfassung.pdf

- [61] „Statusreport: Wärme“, BDEW, Nov. 2023. Zugegriffen: 14. Dezember 2023. [Online]. Verfügbar unter:
https://www.bdew.de/media/documents/Statusreport_Waerme_Stand_17_11_2023_final.pdf
- [62] Verband der Netzbetreiber, Hrsg., *Lastprofile für unterbrechbare Verbrauchseinrichtungen: LPuVe-Praxisleitfaden*, 1. Ausg. Frankfurt am Main Heidelberg: VWEW-Energieverl, 2003.
- [63] U. P. Mueller u. a., „The eGo grid model: An open source approach towards a model of German high and extra-high voltage power grids“, *J. Phys.: Conf. Ser.*, Bd. 977, S. 012003, Feb. 2018, doi: 10.1088/1742-6596/977/1/012003.
- [64] K. Heuck, K.-D. Dettmann, und D. Schulz, *Elektrische Energieversorgung: Erzeugung, Übertragung und Verteilung elektrischer Energie für Studium und Praxis*, 9., Aktualisierte u. korr. Aufl. 2013. Wiesbaden: Springer Fachmedien Wiesbaden Imprint Springer Vieweg, 2013.