

KIVI

Künstliche Intelligenz zur Untersuchung der Versorgungssicherheit mit Elektrizität

Abschlussbericht



Laufzeit: 01.06.2020 bis 30.11.2023

Förderkennzeichen: 03EI1022A / 03EI1022B

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

Autoren

Justin Münch²

justin.muench@hs-duesseldorf.de

Philipp Daun¹

philipp.daun@eonerc.rwth-aachen.de

Marius Tillmanns¹

marius.tillmanns@eonerc.rwth-aachen.de

Dominik Dörr²

dominik.doerr@hs-duesseldorf.de

Jan Priesmann¹

jan.priesmann@eonerc.rwth-aachen.de

Marius Reich²

marius.reich@hs-duesseldorf.de

Dr. Lars Nolting¹

lnolting@eonerc.rwth-aachen.de

Benedikt Prusas²

benedikt.prusas@hs-duesseldorf.de

Prof. Dr.-Ing. Mario Adam²

mario.adam@hs-duesseldorf.de

Prof. Dr.-Ing. Aaron Praktiknjo¹

apraktknjo@eonerc.rwth-aachen.de

¹ RWTH Aachen University, Lehrstuhl für Energiesystemökonomik (FCN-ESE),
Mathieustrasse 10, 52074 Aachen

² University of Applied Sciences Düsseldorf (Hochschule Düsseldorf), ZIES - Zentrum für Innovative Energiesysteme, Münsterstraße 156, 40476 Düsseldorf

Inhaltsverzeichnis

Autoren	2
Inhaltsverzeichnis	3
Kurzbeschreibung	5
Aufgabenstellung	5
Voraussetzungen der Arbeiten	6
Planung und Ablauf des Vorhabens	7
Wissenschaftlicher und technischer Stand	10
Zusammenarbeit mit anderen Stellen	12
1 Einführung	14
1.1 Versorgungssicherheitsmodellierung	14
1.2 Machine Learning	16
1.2.1 Zeitreihenprognose	17
1.2.2 Metamodellierung und Design of Experiments	19
1.2.3 Regressionsmethoden	22
1.3 Ziel und Struktur des Vorhabens	24
2 Datenaufbereitung und Prognosemodelle	26
2.1 Stromlastgang	26
2.2 Erneuerbare Energien	31
2.3 Speicherkapazitäten	33
2.4 Nichtverfügbarkeiten	35
2.5 Importpotential	37
3 Versorgungssicherheitsmodellierung	40
3.1 Probabilistisches Simulationsmodell	40
3.2 Auswahl relevanter Szenarien	50
4 Metamodellierung komplexer Energiesystemmodelle	53
4.1 Voranalyse	53
4.2 Problemstellung und Testszenarien	57
4.3 Methode zur Generierung der Trainingsdaten	59
4.3.1 Statische Methodik zur Abtastung des Versuchsraumes	59
4.3.2 Reduktion der Trainingsdaten	62
4.4 Methodenvergleich an unabhängigen Testszenarien	63
4.5 Bewertung der Metamodellierung	64
5 Fallstudie	67
6 Zusammenfassung und Ausblick	71

6.1	Zusammenfassung	71
6.2	Ausblick	73
7	Weiterverwendung	75
	Fachzeitschriftenartikel.....	75
	Dissertationen.....	75
	Workshops und Präsentationen	76
8	Literaturverzeichnis	79

Kurzbeschreibung

Aufgabenstellung

Das Energiesystem in Deutschland ist im Zuge der Energiewende von Umbrüchen geprägt: Kernenergieausstieg, Kohleausstieg, Ausbau der erneuerbaren Energien und zunehmende Sektorenkopplung ergeben eine Vielzahl an möglichen Szenarien für das zukünftige Energiesystem und damit einhergehend ein großes Maß an Unsicherheit. Energiesystemmodelle bilden dabei häufig die Grundlage für gesellschaftsrelevante Entscheidungen hinsichtlich der Energiesysteme. Angesichts steigender Einspeiseleistungen fluktuierender erneuerbarer Energien und Reduktionen im steuerbaren fossil-nuklearen Kraftwerkspark gewinnt dabei insbesondere die probabilistische Bewertung der Versorgungssicherheit zunehmend an Bedeutung.

Allerdings überträgt sich die zunehmende Komplexität des Energiesystems auch auf die entsprechenden wissenschaftlichen Modelle zur Versorgungssicherheitsanalyse. Zwar haben sich einige probabilistische Modelle zur Beurteilung der Versorgungssicherheit unter Einbeziehung der Wetterabhängigkeit von regenerativer Einspeiseleistung und Last sowie potentieller Ausfälle bzw. Nichtverfügbarkeiten von steuerbaren Kraftwerksblöcken und der zur Verfügung stehenden Importleistung aus Nachbarländern in den vergangenen Jahren etabliert, allerdings stellen sich diese als sehr rechen- und damit zeitintensiv in den Simulationen dar. In der Praxis können aufgrund dieser Beschränkungen deshalb trotz der vorhandenen Unsicherheiten nur wenige Szenarien untersucht werden.

An diesem Punkt ergibt sich ein erhebliches Potential für neue Methoden aus dem Bereich der Data Science. Insbesondere Ansätze aus den Bereichen der künstlichen Intelligenz sowie der Metamodellierung scheinen vielversprechend, um die Zusammenhänge zwischen Modelleingangsgrößen und Modellergebnissen abzubilden, ohne dabei an Beschränkungen hinsichtlich vorhandener Rechenressourcen zu stoßen. Zudem können moderne Methoden der Data Science genutzt werden, um die nötigen Eingangsdaten aufzubereiten.

Im Projekt KIVI werden interdisziplinäre Forschungsansätze der Metamodellierung sowie Datenkonsolidierung und Zeitreihenvorhersage herausgearbeitet, bewertet, übertragen und im Sinne von Fallstudien angewendet.

Im Wesentlichen liegt der Fokus der Untersuchungen auf folgenden **Forschungsfragen**:

- 1) Welche Methoden aus dem Bereich der Data Science eignen sich für die probabilistische Versorgungssicherheitsbewertung?
- 2) Wie können diese Methoden am besten übertragen werden, um:
 - a. Datenreihen aufzubereiten und Unsicherheiten abzuschätzen?
 - b. Den eigentlichen Modellierungsprozess zu vermeiden und somit durch geschickte Metamodellierung Laufzeiten zu reduzieren?
 - c. Umfassendere Versorgungssicherheitsanalysen durch die Vermeidung von Modellierungsaufwand zu ermöglichen?
- 3) Auf welche weiteren Einsatzmöglichkeiten in der Energieforschung lassen sich diese Methoden übertragen?

Das Projekt trägt zum Schließen dieser bestehenden Forschungslücken bei und konzentriert sich dabei insbesondere auf die folgenden Aspekte:

- 1) Erhöhung der Qualität historischer Zeitreihen und der Validität prognostizierter Eingangsdaten.
- 2) Berücksichtigung der Unsicherheiten der Eingangsdaten für die Erhöhung der Ergebnisgüte.
- 3) Bereitstellung einer Alternative für aktuell verwendete Simulations- und Optimierungsmethoden unter Verwendung KI-basierter Ansätze.
- 4) Ermöglichung weitergehender Untersuchungen im Bereich der Versorgungssicherheitsbewertung durch die Einbindung von KI-basierten Methoden (z.B. Vergrößerung des Untersuchungs-raums, Ermöglichung von robuster Optimierung unter Beachtung der Unsicherheiten).

Voraussetzungen der Arbeiten

Die Arbeiten im Rahmen dieses Projektes wurde am Lehrstuhl für Energiesystemökonomik der RWTH Aachen (FCN-ESE), vormals Juniorprofessur für Energieressourcen- und Innovationsökonomik (FCN-JERI), sowie am Zentrum für Innovative Energiesysteme (ZIES) der Hochschule Düsseldorf (University of Applied Sciences Düsseldorf) durchgeführt. Der vorliegende Bericht umfasst die Arbeiten von FCN-ESE sowie ZIES. Das Projekt wurde mit einer Laufzeit von 36 Monaten (01.06.2020 – 31.05.2023) geplant und um sechs Monate bis zum 30.11.2023 kostenneutral verlängert.

Die Arbeitspakete des Projektes wurden von den vorgestellten Zielen abgeleitet und wie folgt strukturiert:

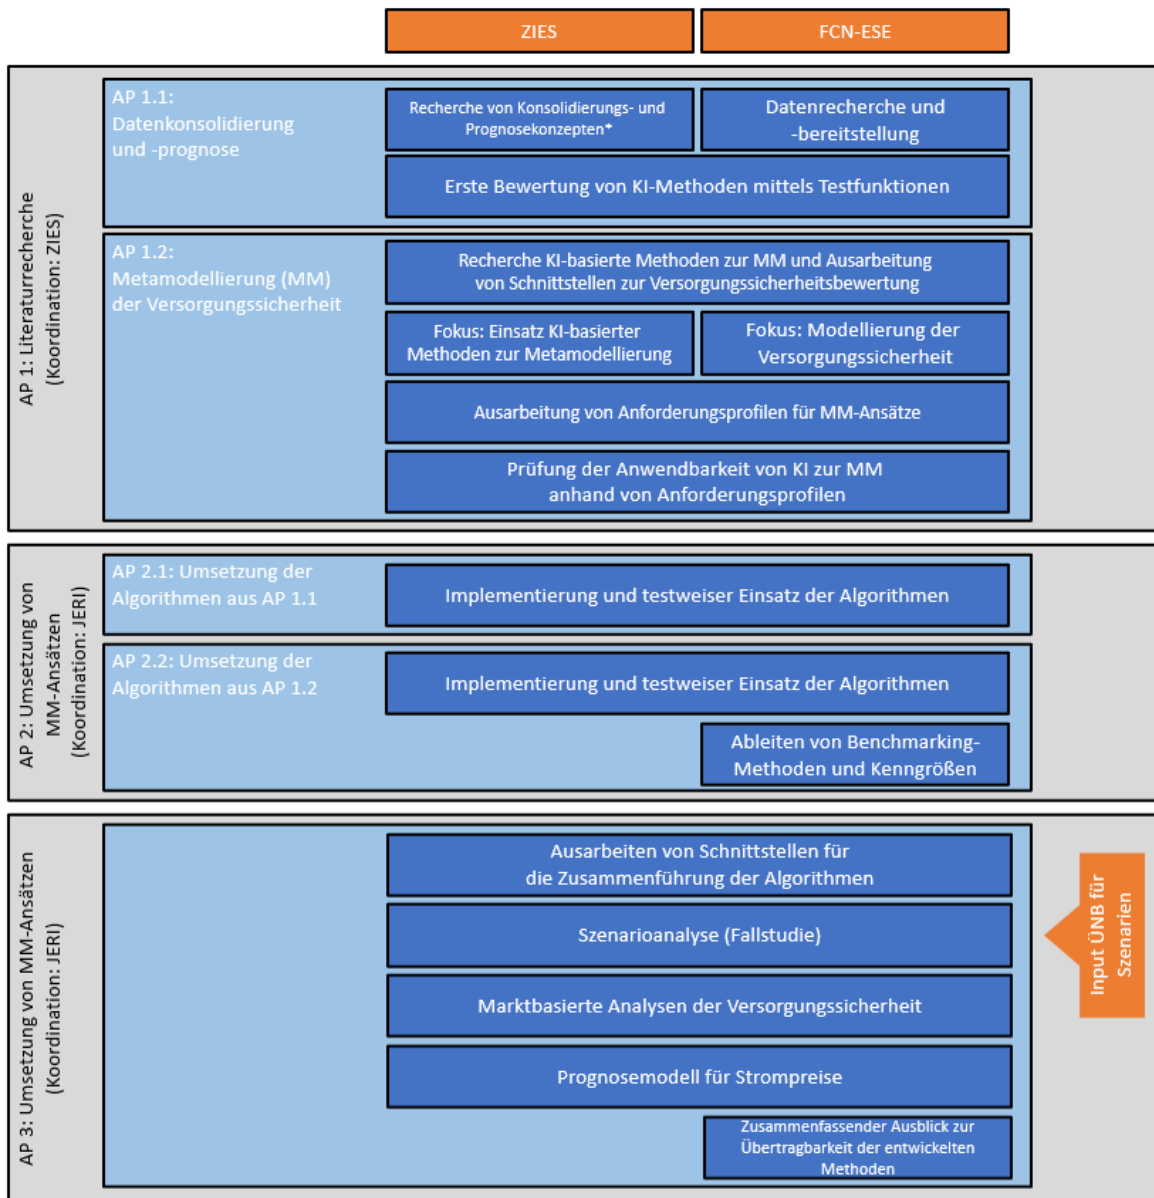


Abbildung 1: Überblick über den Arbeitsplan und wesentliche Beiträge der Verbundpartner (Abkürzungen: IT – Informationstechnologie, KI – künstliche Intelligenz, MM – Metamodellierung, ÜNB – Übertragungsnetzbetreiber)

Planung und Ablauf des Vorhabens

Im **ersten Arbeitspaket** werden für das Projekt relevante Methoden aus dem Gebiet der Data Science literaturbasiert herausgearbeitet und jeweils auf ihre Anwendbarkeit für die Datenkonsolidierung und Zeitreihenprognose sowie die Metamodellierung in Form von Vortests untersucht. Ziel ist es demnach, eine für die weiteren Untersuchungen relevante Auswahl an Methoden aus dem Bereich der Data Science zu erarbeiten. Aufgrund der bereits vorhandenen Erfahrung im Bereich des Data Science beschäftigt sich das ZIES mit einer detaillierten Herausarbeitung möglicher Ansätze, die eine Konsolidierung und Prognose von Daten (AP

1.1) sowie Ansätze für die Metamodellierung von Energiesystemmodellen (AP 1.2) ermöglicht. Die Arbeiten werden in zwei Unterarbeitspakete gegliedert und im Folgenden separat dargestellt:

AP 1.1: Verbesserte Datenkonsolidierung und Prognose der Eingangsdaten

Das ZIES arbeitet eng mit dem Partner FCN-ESE zusammen, um neue Konzepte für die verbesserte Datenkonsolidierung und Prognose von Eingangsdaten für die Metamodellierung von Energiesystemmodellen zu entwickeln, anzuwenden und zu validieren. FCN-ESE sammelt relevante Datenquellen und stellt diese dem Projektkonsortium zur Verfügung. Die Partner forschen, analysieren und bewerten KI-basierte Methoden, die das Potenzial haben, die Datenkonsolidierung und -prognose zu verbessern und die Vorhersage von Unsicherheiten zu ermöglichen. Die Bewertung der Methoden basiert auf dem aktuellen wissenschaftlichen Stand und zu entwickelnden Testfunktionen, die es ermöglichen, das Potenzial der einzelnen Algorithmen durch kleinere Vortests abzuschätzen (Benchmarking). Eine umfassende Datenbasis wird in einer gemeinsamen Datenbank für die weitere Nutzung im Projektverlauf angelegt. Der aktuelle Forschungsstand zu KI-basierten Methoden für Datenkonsolidierung und Zeitreihenprognose wird gründlich erarbeitet. Zudem gibt es zu jedem der ermittelten Ansätze eine erste Einschätzung basierend auf eigenen Testergebnissen, um ihre Eignung für die Versorgungssicherheitsmodellierung zu beurteilen und mögliche weitere Schritte festzulegen.

AP 1.2: Ansätze für die Metamodellierung im Gebiet der Bewertung der Versorgungssicherheit mit Elektrizität

Im zweiten Unterarbeitspaket werden KI-basierte Ansätze entwickelt und bewertet, um den komplexen Zusammenhang zwischen Modelleingangsgrößen und Modellergebnissen für die Bewertung der Versorgungssicherheit mit Elektrizität darzustellen. FCN-ESE und ZIES arbeiten gemeinsam an potenziellen Metamodellierungsansätzen und entwickeln ein Anforderungsprofil, das die wesentlichen Eigenschaften der anwendbaren Ansätze definiert. Zur Erstellung dieses Profils werden Literaturquellen und Vorstudien herangezogen, um geeignete Bewertungskriterien abzuleiten. Schließlich prüfen FCN-ESE und ZIES die Übertragbarkeit der KI-basierten Methoden anhand des Anforderungsprofils. In AP 1.2 werden somit der aktuelle Forschungsstand zu KI-basierten Metamodellierungsmethoden, wie künstlichen neuronalen Netzen und Machine Learning, analysiert. Außerdem werden potenzielle Ansatzpunkte für Metamodellierung in der Versorgungssicherheitsbewertung ermittelt und ein Anforderungsprofil zur Bewertung der Übertragbarkeit auf die Versorgungssicherheitsanalyse erstellt. Basierend auf diesem Profil werden für jeden Metamodellierungsansatz eine erste Einschätzung ihres Potenzials zur Übertragung auf das Gebiet der Versorgungssicherheitsanalyse gegeben.

Im **zweiten Arbeitspaket** werden die in AP 1 als vielversprechend bewerteten und für das Projekt relevanten Methoden aus dem Gebiet der Data Science umfassend implementiert und umgesetzt. Ziel ist es, Methoden zu implementieren und für den Anwendungsfall der Bewertung der Versorgungssicherheit mit Elektrizität aufzubereiten, welche über das Potential verfügen, die Datenkonsolidierung und -prognose für die Energieforschung zu verbessern sowie die Metamodellierung zu ermöglichen. Hierzu werden die Algorithmen zunächst unabhängig voneinander einzeln implementiert und vertiefend (i.e. über die Anwendung von Testfunktionen hinausgehend) getestet, um zu untersuchen, ob sich das in AP 1 auf Basis von

Literaturwerten sowie Benchmarks erarbeitete Potential in der praktischen Anwendung für die Bewertung der Versorgungssicherheit für Elektrizität zeigt. Auch hier teilt sich das Vorgehen in zwei Unterarbeitspakete auf:

AP 2.1: Umsetzung der Algorithmen zur Datenkonsolidierung und Zeitreihenprognose

Auf Basis des in AP 1 zusammengetragenen Datenfundus werden die ebenfalls während AP 1 als vielversprechend bewerteten Algorithmen durch FCN-ESE und ZIES implementiert und testweise eingesetzt. Die Methoden zur Datenkonsolidierung und Zeitreihenprognose werden hinsichtlich ihrer Genauigkeit im Vergleich zu etablierten Ansätzen bewertet. Alle in AP 1.1 als vielversprechend bewerteten Ansätze der Datenkonsolidierung sowie der Zeitreihenprognose werden implementiert und für die Anwendung im Bereich der Versorgungssicherheitsbewertung getestet. Damit liegt eine fundierte Bewertung ihrer Übertragbarkeit auf die Energieforschung unter Berücksichtigung des in AP 1.1 erarbeiteten Datenfundus vor.

AP 2.2: Umsetzung der Algorithmen zur Metamodellierung

Die vielversprechenden Algorithmen zur Metamodellierung aus AP 1 werden implementiert und auf ihre praktische Anwendbarkeit im Bereich der Versorgungssicherheitsmodellierung untersucht. Um ihr Potenzial objektiv bewerten zu können, werden sie mit einem probabilistischen Versorgungssicherheitsmodell nach aktuellem Stand der Technik verglichen. Laufzeitgewinne und Abweichungen in der Ergebnisgenauigkeit werden als Bewertungsgrößen herangezogen. Ein für das Benchmarking benötigtes Simulationsmodell liegt an der RWTH Aachen University als Teil des JERICHO Modells vor. Zusammenfassend entsteht eine fundierte Bewertung ihrer Übertragbarkeit auf die Energieforschung in Bezug auf Genauigkeitsverluste/-gewinne und Laufzeitreduktionen. Zudem wird eine Einschätzung des Nutzens der Algorithmen und Analysemethoden formuliert.

Im **dritten Arbeitspaket** werden die in AP 2 zunächst unabhängig voneinander implementierten Methoden aus dem Bereich der Data Science zusammengefasst und in den Arbeitsfluss der probabilistischen Versorgungssicherheitsanalyse eingefügt. Ziel ist es, den aus der Übertragung von Methoden der Data Science entstandene Mehrwert für die Energieforschung anhand von Fallstudien abzuleiten.

Die sich in Arbeitspaket 2 als praktikabel erwiesenen Algorithmen werden für die Energieforschung zusammengeführt, beginnend mit der Datenkonsolidierung über die Prognose relevanter Zeitreihen bis zur Metamodellierung. FCN-ESE und ZIES implementiert die nötigen Schnittstellen, um die Algorithmen zusammenzuführen. FCN-ESE untersucht in einer Fallstudie für die zukünftige Versorgungssicherheit Europas, welchen Mehrwert KI-basierte Methoden bieten. Bei der Szenarioanalyse werden sowohl literaturbasierte Annahmen als auch Erkenntnisse der Übertragungsnetzbetreiber aus dem Praxisbeirat des Projektes einbezogen. Der Fokus liegt dabei auf der verbesserten Prognosegenauigkeit, vermiedenem Modellierungsaufwand und neuen Analysen durch KI-Methoden. FCN-ESE leitet darüber hinausgehende Anwendungsmöglichkeiten der Algorithmen ab, um einen Mehrwert für andere Energieforschungsanwender zu generieren.

Zusammenfassend werden alle in AP2 als vielversprechend bewerteten Methoden der Data Science mit Hilfe entsprechender Schnittstellen in AP 3 zusammengeführt. Daher sind sowohl die Datenkonsolidierung als auch die Zeitreihenprognose und Metamodellierung nun mit KI-Unterstützung in einem Prozess möglich. Das Potential der herausgearbeiteten Algorithmen

für die Energieforschung wird anhand einer Szenarioanalyse bewertet und weitere Einsatzmöglichkeiten der erarbeiteten Ansätze in Themenbereichen der Energieforschung herausgearbeitet, bewertet und in einer Übersicht zusammengefasst.

Wissenschaftlicher und technischer Stand

Bewertung der Versorgungssicherheit mit Elektrizität

Im interdisziplinären Spannungsfeld zwischen Umweltverträglichkeit, Wirtschaftlichkeit und Versorgungssicherheit müssen im Zuge der voranschreitenden Energiewende optimale Entscheidungen getroffen werden. Die Ergebnisse der Energiesystemmodellierung dienen somit als Referenz, um die heutige Entscheidungsfindung für die bestmöglichen zukünftigen Ergebnisse zu steuern.

Für die Bewertung der Versorgungssicherheit werden nach aktuellem Stand der Forschung zwei verschiedene Ansätze aus dem Bereich der Energiesystemanalyse verwendet: Erstens deterministische Kapazitätsbilanzen der verfügbaren Einspeiseleistung und der Spitzenlast, wie sie etwa von den Übertragungsnetzbetreibern (vgl. [1], [2]). Regulierungsbehörden (vgl. [3]) und Beratungsunternehmen (siehe [4–7]) in einer Vielzahl von Studien verwendet wurden. Zweitens probabilistische Simulationen in hoher zeitlicher Auflösung, die die Wetterabhängigkeit von Last und erneuerbarer Einspeisung widerspiegeln. Dieser Ansatz wurde ebenfalls von Netzbetreibern (vgl. [8,9]) und Beratungsunternehmen (vgl. [10,11]) sowie wissenschaftlichen Studien in unterschiedlichen Detailgraden angewendet.

Die Methodiken unterscheiden sich in mehreren Hinsichten: Zum einen ist die Komplexität der Berechnungen bei probabilistischen Ansätzen viel höher, zum anderen müssen die Ergebnisse deterministischer Ansätze anders interpretiert werden als diejenigen stochastischer Berechnungen. Zudem basieren Kapazitätsbilanzen auf eher einfachen Tabellenkalkulationen, während probabilistische Abschätzungen aufwändige Simulationen von Wettereinflüssen und Verfügbarkeitswahrscheinlichkeiten erfordern (siehe Kapitel 3).

Die Ergebnisse probabilistischer Simulationen spiegeln den stochastischen Charakter realer Bedingungen stärker wider als deterministische Ansätze. So stellen z.B. die Autoren des EU Clean Energy Package [12] fest, dass ein deterministischer Ansatz zur Beurteilung der Sicherheit der Stromversorgung " [...] kein zuverlässiges Bild der Versorgungssicherheitssituation aufgrund des Anstiegs der erneuerbaren Energien in den Stromsystemen vermittelt". Um detaillierte und umfangreichere Untersuchungen im Bereich der Versorgungssicherheit zu ermöglichen, werden derzeit hochkomplexe Energiesystemmodelle entwickelt. Wissenschaftliche Modellierer sind jedoch mit Speicher- und Laufzeitbeschränkungen konfrontiert, wenn sie versuchen, den Detaillierungsgrad zu erhöhen. Es gibt bereits laufende Projekte im Bereich der Energiesystemanalyse, welche versuchen, Wege zum Umgang mit dieser Modellkomplexität zu finden (vgl. BEAM-ME [13] und METIS [14]). Die in diesen Projekten untersuchten Ansätze konzentrieren sich allerdings hauptsächlich auf die effiziente Optimierung von Energiesystemen mit z.B. Zeitreihenaggregationsmethoden und mathematischen Zerlegungsansätzen.

Daher wird das Potenzial aktueller Entwicklungen in der Data Science, wie z.B. die Entwicklung von ausgearbeiteten Metamodellen mit künstlicher Intelligenz (KI), bisher von Forschern mit reinem Fokus auf das Gebiet der Energiesystemanalyse übersehen.

Metamodellierung

Um die Recheneffizienz zu erhöhen, sind Metamodelle sehr gut geeignet. Sie bilden eine funktionale Beziehung zwischen Eingangs- und Ausgangsvariablen basierend auf den zur Verfügung stehenden Informationen ab. Einmal erstellt, liefern sie ihre Ergebnisse in kürzester Zeit. Es können unterschiedliche Ansätze der Metamodellierung angewendet werden, im Folgenden soll exemplarisch näher auf die (klassische) Regression sowie die KI-basierte Anwendung künstlicher neuronaler Netzwerke (*Artificial Neural Networks*, ANN) eingegangen werden:

Während die Durchführung von Regressionen einen eher einfachen und unkomplizierten Ansatz für die Aufgabe der Approximation darstellt, ist die Implementierung von ANN tendenziell anspruchsvoller und erfordert spezifischere Kenntnisse. Dieser Komplexitätsunterschied spiegelt sich in den Möglichkeiten wider, die sich bei der Verwendung der Ansätze zur Modellierung einer funktionalen Beziehung ergeben: Regressionen, oder allgemeiner Polynomfunktionen, haben eine feste parametrische Form, die aus Regressoren und den entsprechenden Regressionskoeffizienten besteht. Letztere werden mit Hilfe der Methode der kleinsten Quadrate ermittelt (vgl. [15,16]). Ihre Approximationsfähigkeiten sind jedoch beschränkt. ANNs sind zur Approximation nichtlinearer funktionaler Beziehungen in der Regel deutlich besser geeignet als Regressionsfunktionen. Zur Erstellung von Metamodellen sind geeignete Informationen aus dem mehrdimensionalen Untersuchungsraum notwendig, der von der Anzahl der zu berücksichtigenden Einflussgrößen aufgespannt wird. Um diese statistisch fundiert zu sammeln, wird das sog. *Design of Experiments* (DoE) verwendet [17].

Viele Anwendungsfälle in der Energieversorgung eine Vielzahl an Einfluss- und Zielgrößen und häufig nichtlineare Beziehungen zwischen Eingangs- zu Ausgangsgrößen. Diese nichtlinearen Zusammenhänge können gewöhnliche Polynomfunktionen nicht abbilden. Hierfür sind Ansätze aus dem Gebiet der Data Science, wie beispielsweise die oben genannten ANN, geeigneter und flexibler. Eine ausführlichere Einführung in ANN gibt [18], während ein zeitgemäßer Überblick über aktuelle Prozesse im Bereich ANNs, *Machine Learning* und *Computational Intelligence* in [19] gegeben wird. Diese modernen KI-basierten Ansätze übertreffen oft die Leistungsfähigkeit klassischer Methoden, wie beispielsweise in [20] bei der Approximation der simulierten Eigenschaften von Energieversorgungssystemen mit dem Ziel der Optimierung von Systemstruktur und -dimensionierung gezeigt. Biedermann et al. (2018) gibt ein Beispiel dafür, dass diese anspruchsvolleren Ansätze auch für experimentelle Aufgabenstellungen sehr gut geeignet sind [21]. Daher sind KI-basierte Ansätze der Metamodellierung in Verbindung mit DoE-Methoden vielversprechend für die Approximation von Systemzusammenhängen und die Vermeidung von Modellierungsaufwand, wodurch gerade in diesem Bereich weiterer Forschungsbedarf besteht.

Datenkonsolidierung und Zeitreihenprognose

Die Analyse von Energiesystemen ist datengetrieben wobei die Qualität der Eingangsdaten die Zuverlässigkeit der Ergebnisse und damit deren Anwendbarkeit als Entscheidungsgrundlage bestimmt. Fehlende Daten und schlechte Qualität der öffentlich zugänglichen Datensätze sind jedoch bekannte Probleme im Bereich der Energiesystemanalyse [22]. Aus diesem Grund hat das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) Projekte wie die *Open Power System Data Platform* (siehe [23]) zur Online-Bereitstellung notwendiger Ein-

gangsdaten für Modellierungszwecke (z.B. meteorologische Daten, elektrische Last, Übertragungskapazitäten etc.) gefördert. Darüber hinaus veröffentlicht das *European Network of Transmission System Operators for Electricity (ENTSO-E)* Daten auf ihrer so genannten Transparenzplattform [24] und die europäische Strombörse *EPEX SPOT* veröffentlicht relevante Daten, insbesondere über die Preise für Strom und andere Rohstoffe, für Nutzer mit Abonnement (vgl. [25]). Die verfügbaren historischen Datensätze und Zeitreihen sind jedoch oft durch fehlende Datenpunkte und widersprüchliche Angaben gekennzeichnet. So lässt sich der Bedarf an Datenaufbereitungsalgorithmen ableiten, die in der Lage sind, Zeitreihen im Bereich der Energiesystemmodellierung zu konsolidieren.

Die Verbesserung der Qualität historischer Zeitreihen wirkt sich zudem deutlich positiv auf die Validität prognostizierter Zeitreihen aus. Letztere werden als Inputdaten für Zukunftsszenarien und somit als Eingangsgrößen für die klassische Energiesystem- oder Metamodellierung benötigt. Daher ist die Vorhersage von Zeitreihen eine weitere Kernaufgabe in diesem Forschungsgebiet. Jüngste Studien (für einen guten Überblick, siehe [26]) haben bereits das Potenzial von Methoden aus dem Bereich der KI zur Vorhersage von Zeitreihen mit Relevanz für die Energiesystemanalyse gezeigt. Eine besondere Bedeutung kommt dabei der Prognose von Lastzeitreihen zu. Die Prognose lässt sich hierbei gemäß eines von Srinivasan und Lee (1995) [27] veröffentlichten und durch Hong und Fan (2016) [28] erweiterten Überblicks in vier verschiedene Vorhersagezeiträume von < 30 Minuten bis > 1 Jahr kategorisieren.

Je nach Zeithorizont erfüllen die Stromlastprognosen verschiedene Funktionen: Kurzfristige Prognosen sind für den Kraftwerksbetrieb und die Bereitstellung von Ausgleichsenergie unerlässlich. Mittelfristige Prognosen werden z.B. für den Einkauf von Ressourcen verwendet. Langfristprognosen werden zur Planung und zum Bau von Energieversorgungs- und Übertragungsanlagen, zur Information der politischen Entscheidungsträger sowie als Eingangsparameter für die wissenschaftlichen Modelle verwendet [29].

Für den Regelbetrieb von Kraftwerken und einen effizienten Lastausgleich müssen kurzfristige Prognosen die Netzlast in räumlicher Auflösung vorhersagen können [30]. Hobbs et al. (1999) beschreiben, dass eine Reduzierung des Vorhersagefehlers um 1% zu Einsparungen in Millionenhöhe führen kann [31]. Neben der Effizienzsteigerung garantieren kurzfristige Prognosen auch die Versorgungssicherheit. Genauere Prognosen sind für einen reibungslosen Betrieb unerlässlich, insbesondere mit dem steigenden Anteil erneuerbarer Energien. Im Projekt KIVi wurde die Anwendbarkeit von Vorhersagemethoden, welche auf künstlicher Intelligenz basieren, im interdisziplinären Kontext weiterentwickelt, um die bestmögliche Qualität der Eingangsdaten für die Energieforschung zu gewährleisten.

Zusammenarbeit mit anderen Stellen

Die gesamten Projektarbeiten wurden vom oben beschriebenen Konsortium ausgeführt. Die Zusammenarbeit innerhalb des Projektteams wurde dank zweiwöchentlicher Online-workshops und halbjährlicher Projekt- und Praxisbeiratstreffen in Präsenz gewährleistet. Die Forschungsergebnisse wurden auf verschiedenen wissenschaftlichen Tagungen und Konferenzen vorgestellt und diskutiert (siehe Kapitel 7, *Weiterverwendung, insb. Workshops und Präsentationen*). Des Weiteren wurden mehrere Expertenworkshops im Rahmen des Forschungsnetzwerkstreffens Energiesystemanalyse durchgeführt.

Darüber hinaus wurde eine enge Zusammenarbeit mit den beteiligten Übertragungsnetzbetreibern im Rahmen einer assoziierten Partnerschaft über den gesamten Projektverlauf angestrebt. Die **50Hertz Transmission GmbH**, die **Amprion GmbH**, die **TenneT TSO GmbH** sowie die **TransnetBW GmbH** sind als Übertragungsnetzbetreiber in Deutschland für die Sicherheit der Elektrizitätsversorgung mitverantwortlich und waren daher inhaltlich sehr an der Verknüpfung neuer Erkenntnisse aus dem Bereich der Data Sciences mit der Untersuchung der elektrischen Versorgungssicherheit interessiert.

Aus diesem Grund standen die genannten Übertragungsnetzbetreiber als ständige Mitglieder eines projektbegleitenden Praxisbeirats zur Verfügung. Im Rahmen dieser Beiratstätigkeiten präsentierte das Projektkonsortium in halbjährig stattfindenden Workshops den Projektzwischenstand, um einen Transfer der erarbeiteten Methodiken zu ermöglichen sowie die Praxisnähe der Forschung sicherzustellen. Auch wurde den Übertragungsnetzbetreibern im Zuge der Beiratstreffen die Möglichkeit gegeben, ihre fundierten Fachkenntnisse in die Ausgestaltung des in Arbeitspaket 3 verwendeten Szenariorahmens einfließen zu lassen.

1 Einführung

Kapitel 1 liefert eine Einführung in den wissenschaftlichen und anwendungsbezogenen Status Quo der Versorgungssicherheitsmodellierung. Des Weiteren werden Grundlagen aus dem Bereich Machine Learning für die Anwendung im Bereich der Zeitreihenprognose, Metamodellierung und Ausgestaltung eines Design of Experiment (DoE) sowie im Bereich der Regressionsmethoden vorgestellt. Eine Übersicht über das Ziel und die Struktur des Projektes KIVi und des vorliegenden Abschlussberichtes runden das vorliegende Kapitel ab.

1.1 Versorgungssicherheitsmodellierung

Im Wesentlichen können zwei Arten der Modellierung der Versorgungssicherheit unterschieden werden: **deterministische Leistungsbilanzen** und **probabilistische Simulationen**. Innerhalb dieser Modellkategorien bestehen wiederum Varianten hinsichtlich des Detailgrads der Abbildung des Energiesystems.

Deterministische Leistungsbilanzen werden von den Übertragungsnetzbetreibern (ÜNB) auf nationaler Ebene (vgl. deutschen Übertragungsnetzbetreibern [2] und auf internationaler Ebene (vgl. [1]), von Regulierungsbehörden wie der BNetzA [32], von Beratungsunternehmen (vgl. Energy Brainpool [5] und Prognos [7]) und von Think Tanks (vgl. Agora Energiewende [4]) verwendet. Weiterhin wird dieser Ansatz in aktuellen wissenschaftlichen Berechnungen verwendet, oft in Kombination mit Energiesystemmodellen (vgl. Coester et al. [33]). [34]

Die zweite Methode der probabilistischen Simulation bezieht bei der Bewertung der Versorgungssicherheit mit Elektrizität stochastische Einflüsse in hoher Auflösung ein. Diese Einflüsse umfassen die Wetterabhängigkeit der elektrischen Last sowie der Einspeiseleistung erneuerbarer Elektrizitätserzeugungsanlagen auf der einen Seite und die Nichtverfügbarkeiten einzelner Kraftwerksblöcke im steuerbaren Kraftwerkspark auf der anderen Seite. Dieser Ansatz wird ebenfalls von den ÜNB auf internationaler Ebene (vgl. Pentalaterales Energieforum [9] und entso-e [35]), von Beratungsunternehmen für umfassendere Studien (vgl. frontier Economics und FOMAET Services [36]) und für wissenschaftliche Bewertungen (vgl. z.B. Praktijnjo und Dittmar [37] und DLR und IER [38]) verwendet. [34]

Beide Methoden unterscheiden sich in zweierlei Hinsicht: Zum einen ist die Komplexität der Berechnungen sowie die Anforderungen an die verfügbaren Daten bei probabilistischen Ansätzen deutlich höher. Zum anderen müssen die Ergebnisse der deterministischen Ansätze anders interpretiert werden als die von probabilistischen Schätzungen. Prognosespannen für verfügbare Kapazitäten und Spitzenlast beruhen dabei auf recht einfachen Tabellenkalkulationen, während probabilistische Bewertungen fortgeschrittene Simulationen von Wettereinflüssen und Kapazitätsverfügbarkeiten erfordern. [34]

Nolting (2021) stellt in seiner Dissertation jeweils die wesentlichen Treiber von Komplexität in Energiesystemmodellen sowie ihre Abbildung in deterministischen Leistungsbilanzen gegenüber. Dabei wird ersichtlich, dass insbesondere der Fokus von Kapazitätsbilanzen auf die Spitzenlaststunde als kritischen Zeitpunkt für die Bewertung der Versorgungssicherheit mit Elektrizität die Abbildbarkeit von Komplexitätstreibern im Energiesystem einschränkt. Somit ist der Aussagegehalt der deterministischen Analysen als reduziert anzusehen. Insgesamt

abstrahieren beide Methoden vom realen System, allerdings bilden probabilistische Simulationsmodelle ein umfassenderes Bild ab, da deterministische Kapazitätsbilanzen als Teilmodelle solcher Simulationen definiert werden können [39]. Die Ergebnisse der probabilistischen Simulationen spiegeln die stochastische Natur der realen Bedingungen besser wider als deterministische Ansätze und sind daher für die Analyse von Systemen mit einem hohen Anteil an fluktuierenden erneuerbaren Energien besser geeignet [34]. Einen zusammenfassenden Vergleich der Modellierungsansätze auf Basis der Analysen von Priesmann et al. (2021) liefert Tabelle 1 [40].

Tabelle 1: Zusammenfassender Vergleich der Modellierungsansätze für die Versorgungssicherheitsbewertung [19,40]

	Deterministische Leistungsbilanz	Probabilistische Simulation
Ansatz	Top-down-Ansatz , d.h. die Modellierung basiert auf einer hohen Entstehungsebene.	Bottom-up-Ansatz , d.h. die Modellierung basiert auf Teilelementen des gesamten Energiesystems.
Modellkomplexität	Geringe Modellkomplexität , d.h. Aufwand und Kosten für Implementierung und Rechenzeit sind praktisch vernachlässigbar.	Hohe Modellkomplexität , d.h. erheblicher Aufwand und Kosten für die Implementierung sowie lange Rechenzeiten und hoher Speicherbedarf
Berechnete Kennzahlen der Versorgungssicherheit	Verbleibende Kapazität (RC) : Differenz zwischen der verfügbaren Kapazität und der Spitzenlast. Dieser Überschuss steht zur Verfügung, um unerwartete Lasten zu decken und nicht einkalkulierte Kraftwerksausfälle zu kompensieren.	• Lastausfallwahrscheinlichkeit (LoLP, Loss of Load Probability) • Erwarteter Lastausfall (LoLE, Loss of Load Expectation) • Erwartete nicht gedeckte Energie (EEnS, Expected Energy not Served) Genauere Betrachtung siehe Kapitel 3.1
Gemeinsamer Ansatz	Fokus auf Spitzenlaststunden sowie Berücksichtigung eines (Worst-Case-)Wetterjahres	Berücksichtigung von 8.760 Stunden pro Szenariojahr sowie Analyse der verschiedenen Wetterjahre

Aus dem Vergleich der beiden Modellierungsansätze lässt sich allerdings ein **Komplexitätsdilemma** ableiten: Je anspruchsvoller die vorherrschende Forschungsfrage ist, desto mehr Details des zugrundeliegenden Systems müssen abgebildet werden. Da die Komplexität des Energiesystems im Zuge von Liberalisierung und Energiewende zunimmt, führt eine detaillierte Abbildung unweigerlich zu komplexen Modellen. Die Genauigkeit komplexer Modelle hängt jedoch wiederum stark von der Qualität der Eingangsdaten ab. Die Unsicherheiten bezüglich der notwendigen Eingangsdaten für komplexe Modelle sind erheblich, insbesondere im Hinblick auf Zukunftsszenarien für Langfristprognosen. Für die Beantwortung komplexer Forschungsfragen im Zusammenhang mit der Bewertung der Versorgungssicherheit mit Elektrizität müssen daher hohe Unsicherheiten bezüglich der Modellergebnisse berücksichtigt werden [39]. Weniger detaillierte Modellierungsansätze sind in diesem Kontext insbeson-

dere dazu geeignet, Überblickswissen zu generieren und weniger anspruchsvolle Forschungsfragen unter Berücksichtigung der Qualität und Verfügbarkeit der notwendigen Eingabedaten sowie der Zielgruppe für die Ergebnisse zu beantworten. [39,41]

Aus der großen Anzahl der Studien, der Bandbreite der unterschiedlichen und oft gegensätzlichen Hauptergebnisse und der Heterogenität der Autoren und Auftraggeber lässt sich schließen, dass ein erheblicher Bedarf besteht, die wissenschaftliche Grundlage für fundierte Bewertungen der Stromversorgungssicherheit zu schaffen. Darüber hinaus erfordert die mit den unterschiedlichen Eingangsdaten einhergehende Unsicherheit der Ergebnisse die Bewertung einer größeren Vielfalt von Szenarien, um mögliche zukünftige Entwicklungen abzubilden. Im Projekt KIVi wurden daher Methoden aus den Bereichen KI übertragen, um zu einer fundierteren Bewertung der Stromversorgungssicherheit beizutragen. [40]

Auf Grundlage eines ausführlichen Vergleichs der beiden bestehenden Modellierungsansätze sowie den Empfehlungen im EU Clean Energiepaket [12] beinhaltet das Projekt KIVi die Modellierung der Versorgungssicherheit auf Grundlage des probabilistischen Simulationsansatzes. Allerdings unterscheidet sich das probabilistische Simulationsmodell im Projekt von bestehenden Ansätzen, da es nicht auf Monte-Carlo-Simulationen beruht (wie z. B. von entso-e [35]), sondern auf den Verfügbarkeiten einzelner Kraftwerksblöcke. Diese Verfügbarkeiten werden mit einer Bernoulli-Verteilung modelliert und mittels rekursiver Faltung aggregiert (siehe Kapitel 3). Unser Ansatz zeichnet sich im Wesentlichen durch drei Aspekte aus:

- 1) Die realistische Annahme der stochastischen Unabhängigkeit der Nichtverfügbarkeiten der einzelnen Kraftwerksblöcke
- 2) Die Anwendung eines Bottom-up-Ansatzes zur Abbildung des emergenten Systemverhaltens ausgehend von auf der Ebene der einzelnen Kraftwerksblöcke
- 3) Die inhärente Abbildung von Portfolioeffekten

Damit stellt das im Projekt KIVi entwickelte Modell eine wesentliche Weiterentwicklung des derzeitigen Stands der Technik dar [34]. Des Weiteren, geben wir Einblicke in den Stand der Versorgungssicherheit in Mitteleuropa, indem wir das neu entwickelte Modell mit realen Daten und realistischen Prognosen anwenden, anstatt das Modell mit Hilfe von Anwendungsbeispielen zu speisen (vgl. Pambour et al. [42]). Eine Einführung in das probabilistische Simulationsmodell des Projektes KIVi bietet Kapitel 3.

1.2 Machine Learning

Im nachfolgenden wird ein umfangreiches Teilgebiet der Künstlichen Intelligenz, das sogenannte Maschinelle Lernen (ML), in einer knappen, zusammenfassenden Darstellung vorgestellt. Für einen ausführlichen Überblick, insbesondere vor dem Hintergrund der Energietechnik, wird auf die im Zuge dieses Forschungsprojektes entstandene Review-Veröffentlichung *Artificial intelligence and design of experiments for resource adequacy assessment in power systems* [43] verwiesen.

Das ML umfasst alle Methoden, welche sich mit der künstlichen Generierung von Wissen aus Erfahrung befassen. Dies bedeutet, dass Algorithmen über einen Lernprozess Muster und

Gesetzmäßigkeiten in Daten erkennen und dadurch lernen, spezifische Problemstellungen zu lösen. ML kann in die drei Hauptmethoden Überwachtes Lernen (Supervised Learning), Unüberwachtes Lernen (Unsupervised Learning) und Bestärkendes Lernen (Reinforced Learning) eingeteilt werden [44]. Im Bereich der simulativen Bewertung der Versorgungssicherheit mit Elektrizität bietet vor allem die Regression aus dem Bereich des Überwachten Lernens einen Mehrwert. Hierbei erfolgt der Lernprozess anhand von Daten mit direktem Feedback. Diese Methoden können zur verbesserten Datenkonsolidierung sowie zur Prognose von zeitlich aufgelösten Randbedingungen (Zeitreihenprognose) und zur Reduktion von Rechenzeiten über eine Prognose der Ergebnisse zeitaufwändiger Simulationen (Metamodellierung) eingesetzt werden.

Der im KIVI-Projekt verfolgte methodische Ansatz kann Abbildung 2 entnommen werden.




Abbildung 2: Schematische Darstellung des methodischen Ansatzes (KIVI-Projekt)

1.2.1 Zeitreihenprognose

Die Zeitreihenprognose (i.E. *Time Series Forecasting*) ermöglicht die Prognose von zeitlich aufgelösten Randbedingungen, wie beispielsweise den Verlauf des Stromlastganges. In Abhängigkeit zur konkreten Problemstellung (Prognosezeitraum, Auflösung, Datenverfügbarkeit etc.) können unterschiedliche methodische Lösungsansätze (uni-/multivariate Vorgehensweise, ML-Methode, Prognosestrategie) angewendet werden. Im nachfolgenden wird näher auf die für die Zeitreihenprognose spezifischen Lösungsansätze, d.h. insbesondere auf mögliche Prognosestrategien, näher eingegangen. Einen Überblick über Regressionsmethoden aus dem ML-Bereich wird in Kapitel 1.2.3 gegeben.

Abbildung 3 zeigt schematisch die Vorgehensweise zur Prognose von hochaufgelösten Zeitreihen.




Abbildung 3: Übersicht Zeitreihenprognose

Uni-/ Multivariate Vorgehensweise:

Das prinzipielle Vorgehen kann grob in uni- und multivariat unterteilt werden. Bei der univariaten Vorgehensweise wird lediglich die zu prognostizierende Zeitreihe zur Erstellung des Prognosemodells verwendet. Hierbei muss zwangsläufig der Zeitverlauf dem Prognosemodell antrainiert werden, sodass z.B. eine rekursive mehrstufige Prognosestrategie verwendet werden muss. Bei der multivariaten Vorgehensweise hingegen können zusätzliche Zeitreihen, welche einen Einfluss auf die zu prognostizierende Zeitreihe haben, zur Erstellung des Prognosemodells verwendet werden. Die zusätzlichen Zeitreihen könnten z.B. kalendarische Informationen, Wetterdaten etc. enthalten.

Prognosestrategien:

Unterschieden werden kann zwischen drei Grundprognosestrategien: direkte mehrstufige Prognosestrategie (i.E. *Direct Strategy*), rekursive mehrstufige Prognosestrategie (i.E. *Recursive Strategy*) und die Strategie der mehreren Ausgänge (i.E. *Multiple Output Strategie*). Auch eine Kombination aus den drei Grundprognosestrategien ist möglich. [45]

Bei der rekursiven mehrstufigen (RM)-Prognosestrategie wird der zeitliche Zusammenhang dem Prognosemodell antrainiert, indem ein Zusammenhang zwischen dem Verlauf der vorigen Zeitschritte und dem aktuellen Zeitschritt hergestellt wird. Dies kann sowohl univariat als auch multivariat umgesetzt werden. Die hierfür verwendeten Zeitreihen werden als sogenannte *lag features* bezeichnet. Im Gegensatz dazu erfolgt bei der direkten mehrstufigen (DM)-Prognosestrategie der Lernprozess unabhängig von den vorigen Zeitschritten. Vorteilhaft an dieser Prognosestrategie ist, dass im Gegensatz zu einer RM-Prognosestrategie Abweichungen bei der Prognose keinen Einfluss auf die Prognose der nachfolgenden Zeitschritte haben, sodass es nicht zu einer Fehlerfortpflanzung kommt. Allerdings muss die direkte Prognosestrategie multivariat mit kalendarischen Informationen und ggf. zusätzlichen

Features erfolgen, um einen zeitlichen Zusammenhang dem Prognosemodell anzutrainieren und eine Prognosemodellbildung für jeden einzelnen Prognoseschritt zu vermeiden. In Abbildung 4 werden die drei Grundprognosestrategien für den multivariaten Anwendungsfall schematisch dargestellt.




Abbildung 4: Übersicht über Grundprognosestrategien

1.2.2 Metamodellierung und Design of Experiments

Metamodellierung ist eine mögliche Methode, um die Analysetiefe zu steigern, wenn die Zeit zur Generierung der zur Analyse benötigten Ergebnisse die Analysetiefe beschränkt. Verantwortlich hierfür sind in der simulativen Analyse typischerweise hohe Rechenlaufzeiten. Die Methodik zielt drauf ab, einen Zusammenhang zwischen den Eingangs- und den Ausgangsdaten des Simulationsmodelles herzustellen, indem das Systemverhalten des Simulationsmodelles über eine Regressionsmethode abgebildet wird, siehe Abbildung 5. Eine Vielzahl an möglichen klassischen Regressionsmethoden aus dem ML Bereich, z.B. Gauß Prozess Regression, oder auch moderne Methoden aus dem Teilbereich des ML dem sogenannten Deep Learning (DL), welcher künstliche neuronale Netze (KNN) umfasst, stehen hierfür zur Verfügung (siehe Kapitel 1.2.3).




Abbildung 5: Schematische Darstellung der Metamodellierung [46]

Im Gegensatz zur Zeitreihenprognose kann zur Erstellung des Regressionsmodells bei der Metamodellierung nicht auf vorhandene historische Daten zurückgegriffen werden. Stattdessen müssen die Ein-/ Ausgangsdaten über das Simulationsmodell generiert werden. Die Herausforderung hierbei ist, dass die Menge der generierten Ein-/ Ausgangsdaten einerseits ausreichend groß ist, um ausreichend Informationen über das Systemverhalten zu erhalten und andererseits möglichst klein ist, da mit steigender Anzahl die benötigte Simulationszeit zur ihrer Ermittlung ansteigt. Einen methodischen Ansatz zur Lösung dieser Herausforderung bietet das sogenannte Design of Experience (DoE). Dieser methodische Ansatz zielt darauf ab, den Versuchsraum des Regressionsproblems mithilfe von statistischen Methoden möglichst effektiv abzutasten. Der Versuchsraum ist ein mehrdimensionales Konstrukt, welcher durch die Minima und Maxima der Eingangsgrößen aufgespannt wird. Mit steigender Anzahl der Eingangsgrößen steigen somit auch die Dimensionalität des Regressionsproblems und gleichzeitig die Anforderungen an die Ein-/ Ausgangsdaten sowie an die Regressionsmethode. Die über eine statistische DoE-Methode ermittelten Eingangsdaten- bzw. Faktorkombinationen werden als Versuchsplan (i.E. *Design*) bezeichnet. In Abhängigkeit zur Problemstellung und der Zielsetzung zur Abtastung des Versuchsraumes bietet DoE eine Vielzahl an unterschiedlichen Methoden zur Versuchsplanerstellung und Kombinationen daraus.

Nachfolgend wird lediglich eine Auswahl an Strategien zur Erstellung von Versuchsplänen, deren prinzipielles Vorgehen für die vorliegende Arbeit von besonderer Bedeutung ist, näher vorgestellt. Für einen umfassenden Überblick über DOE-Methoden wird auf die weiterführende Fachliteratur von Montgomery [47] und Siebertz et al. [48] verwiesen.

Voll-/ teilfaktoriellen Versuchspläne:

Für lineare Zusammenhänge sind die wichtigsten Versuchspläne die voll-/ teilfaktoriellen Versuchspläne (i.E. full-factorial and fractional factorial designs) nach dem Yates-Standard [49]. Diese Versuchspläne enthalten Extremwertkombinationen auf den Eckpunkten des Versuchsraums (Abbildung 6). Die Anzahl der Faktorkombinationen ergibt sich aus der Anzahl

der variablen Faktoren k (=Eingangsgrößen). Ein vollfaktorieller Versuchsplan enthält 2^k Faktorkombinationen und ein teilfaktorieller Versuchsplan $2^{(k-p)}$ Faktorkombinationen, wobei p die Anzahl der Vermengungen darstellt. Bei teilfaktoriellen Versuchsplänen gehen Informationen durch die Vermengung von Einflussgrößen mit (vermeintlich) vernachlässigbaren Wechselwirkungen verloren, während vollfaktorielle Versuchspläne sämtliche Extremwertkombinationen der Eckpunkte des Versuchsraumes enthalten. Teilfaktorielle Versuchspläne werden nur verwendet, wenn die Vermengung von Variablen offensichtlich vernachlässigbar ist oder wenn die Anzahl der Versuche aus Effizienzgründen reduziert werden soll. Bei nichtlinearen Zusammenhängen sind diese Versuchspläne nicht ausreichend, können allerdings zusätzlich zur Abtastung der Eckpunkte des Versuchsraumes eingesetzt werden.




Abbildung 6: Dreidimensionaler voll-/ teilfaktorieller Versuchsplan

Latin-Hypercube-Design:

Zur Abtastung des Versuchsraumes bei nichtlinearen Zusammenhängen, insbesondere bei rechnergestützter Entwicklung (i.E. computer-aided engineering), bzw. zur Abtastung des Zwischenraumes zwischen den Minima und Maxima der Einflussgrößen werden zunehmend raumfüllende Versuchspläne eingesetzt. Ein Beispiel für diese Art von Versuchsplänen ist der sogenannte Latin-Hypercube-Design (LHD) [50,51]. Beim LHD werden die Faktorkombinationen mit Hilfe eines stochastischen Verfahrens bestimmt, z. B. durch Verwendung einer zufällig permutierten Anordnung, um den vollständigen Versuchsplan nach einer bestimmten Logik zu konstruieren [52]. Diese Methode ähnelt der Monte-Carlo-Methode, bei der die Faktorkombinationen ebenfalls zufällig bestimmt werden. Im Gegensatz dazu werden beim Latin Hypercube Methodiken verwendet, welche eine gleichmäßige Abdeckung des gesamten mehrdimensionalen Versuchsraumes gewährleisten, siehe Abbildung 7 für einen beispielhaften dreidimensionalen LHD. Ein gut konstruierter LHD weist mit der gleichen Anzahl an Faktorkombinationen eine deutlich geringere globale mittlere Varianz als ein rein zufälliger, mit Monte-Carlo konstruierter, Versuchsplan auf.




Abbildung 7: Latin-Hypercube Design (k=3)

Das auf Basis der Simulationsergebnisse an den Faktorkombinationen des verwendeten Versuchsplanes fertig erstellte Metamodell besitzt Gültigkeit innerhalb des definierten Versuchsraumes und kann im Anschluss die Ausgangsdaten des Simulationsmodelles innerhalb dieser Grenzen, d.h. sämtliche Faktorkombinationen zwischen den Minima und Maxima der Eingangsgrößen, in wenigen Millisekunden prognostizieren.

1.2.3 Regressionsmethoden

Wie dem vorstehenden entnommen werden kann, stehen für die Aufgabenbereiche Zeitreihenprognose und Metamodellierung eine Vielzahl von ML-Methoden zur Verfügung. Nachfolgend wird lediglich eine kleine Auswahl näher vorgestellt, welche eine größere Bedeutung für das vorliegende Projekt haben.

Entscheidungsbäume:

Die sogenannten Entscheidungsbäume (i.E. *Decision Trees*) werden häufig in der Regression/ Klassifikation eingesetzt und deren Bezeichnung basiert auf der baumähnlichen Struktur der Methode. Zur Ausgestaltung der Methodik ist eine Vielzahl unterschiedlicher algorithmischer Varianten (z.B. *Random Forest*, *eXtreme Gradient Boosting* etc.) entwickelt worden. Grundlegend wird die Methode durch Knoten und Verbindungen aufgebaut, wobei jeder Knoten eine Entscheidungsregel und jede Verbindung eine Überprüfung einer bestimmten Bedingung repräsentiert. Der Lernprozess funktioniert durch eine wiederholte Unterteilung der Daten, beginnend an der Wurzel über die Verzweigungen (Knoten/ Verbindungen) hin zu den Blättern. Dieser Prozess wird solange durchgeführt bis alle Daten eindeutig klassifiziert wurden oder beispielsweise eine Stoppbedingung erfüllt wurde. [53]

Gauß Prozess Regression:

Der Gauß-Prozess ist ein stochastischer Prozess, bei dem für jede Zufallsvariable eine multivariate Normalverteilung angenommen wird. Eine multivariate Normalverteilung wird durch einen Mittelwertvektor und eine Kovarianzmatrix definiert, sodass ein Gauß-Prozess durch eine Mittelwert- und Kovarianzfunktion definiert wird. Dabei beschreibt im Allgemeinen die

Kovarianzfunktion die Korrelation zwischen den Zufallsvariablen und definiert die Glattheit der Funktion [54]. Wenn eine Gauß Prozess Regression (GPR) auf überwachte Lernprobleme angewendet wird, liefert diese eine Verteilung über Funktionen, welche Unsicherheiten nutzen. GPR kann für eine Vielzahl von Aufgaben im Rahmen des überwachten Lernens verwendet werden, z. B. zur Erkennung von Anomalien [55] oder als Grundlage für die modellprädiktive Steuerung [56]. Aufgrund von Rechenbeschränkungen werden GPR in der Regel für kleine bis mittelgroße Datensätze verwendet, allerdings werden bei aktuelleren Forschungen Lösungsansätze zur Anwendung auf Problemstellungen mit größeren Datensätzen untersucht [57].

Künstliche neuronale Netze (KNN):

Bei datenintensiven und hochdimensionalen Problemstellungen finden verstärkt Methoden des DLs bzw. auf künstlichen Neuronalen Netzen basierende Methoden Anwendung. Ursächlich hierfür ist vor allem die Fähigkeit, große Datenmenge verarbeiten zu können. Künstliche Neuronale Netze sind vom menschlichen Gehirn inspiriert. Hierbei werden Algorithmen, die sogenannten Neuronen, in Schichten zwischen Ein- und Ausgängen angeordnet. Die Eingangsdaten werden von den Neuronen empfangen und weiterverarbeitet, indem mit Hilfe einer Aktivierungsfunktion gewichtete Summen gebildet werden. Über einen iterativen Trainingsprozess werden die zunächst zufälligen Gewichte der Neuronen angepasst, sodass eine definierte Fehlerfunktion minimiert wird.

Hierbei kann zwischen sogenannten *Feed-Forward Neural Networks* (FFNN) und *Recurrent Neural Networks* (RNN) unterschieden werden. RNNs besitzen, im Gegensatz zu herkömmlichen FFNNs, die Fähigkeit, Werte aus vorherigen Zeitschritten beim Training des Netzes zu berücksichtigen. Genauso wie der generelle Aufbau von künstlichen neuronalen Netzen vom menschlichen Gehirn inspiriert wurde, ist die Fähigkeit von RNNs der Versuch, das menschliche Gedächtnis nachzuempfinden. Aus diesem Grund wird bei RNNs auch häufig vom „Kurzzeitgedächtnis“ gesprochen. In Abbildung 8 werden die Netzstrukturen von FFNNs und RNNs schematisch dargestellt.




Abbildung 8: Schematischer Vergleich Feed-Forward Neural Network (FFNN) und Recurrent Neural Network (RNN)

Die ursprüngliche RNN-Methode wurde durch die *Long Short-term Memory* Methode (LSTM) von Hochreiter und Schmidhuber 1997 beschrieben und durch die *Gated Recurrent Units* Methode (GRU) von Cho et al. 2014 weiterentwickelt. Diese Verfahren lösen Probleme, die je nach Komplexität der vorliegenden Problematik auftreten können, wie beispielsweise instabile Gradienten und begrenztes Kurzzeitgedächtnis. Nachfolgend werden die ursprünglichen RNNs als „vanilla RNN“ (VRNN) bezeichnet, da RNN als Oberbegriff für VRNN, LSTM und GRU zu verstehen ist.

Die vorgenannten RNNs sind allerdings nicht die einzigen neuronalen Netze, die zur Vorhersage von Zeitreihen eingesetzt werden können. Auch *Feed-Forward Neural Networks*, wie beispielsweise mehrschichtige Perzeptrons (*multilayer perceptron*, kurz MLP), können bei kurzen Zeitreihen effektiv eingesetzt werden. Für sehr große Datenmengen bieten sich die sogenannten *Convolutional Neural Networks* (CNN) an. Diese kommen vorrangig bei Audiosamples, Bildverarbeitung oder Texten aufgrund der anwendungsspezifisch großen Datenmenge zum Einsatz, können jedoch auch zur Prognose von Zeitreihen eingesetzt werden.

1.3 Ziel und Struktur des Vorhabens

Das Hauptziel des Projekts KIVi besteht darin, moderne Methoden der Data-Science in der Versorgungssicherheitsbewertung zu untersuchen und anzuwenden. Um die im Kapitel **Kurzbeschreibung** vorgestellten Forschungsfragen zu beantworten, konzentriert sich das Projekt auf Konzepte zur Verbesserung der Datenkonsolidierung und Zeitreihenprognosen sowie auf Methoden zur Metamodellierung von Energiesystemanalysen basierend auf künstlicher Intelligenz (KI). Diese Konzepte werden in vier Schritten behandelt: Ausarbeitung, Bewertung, Übertragung und Anwendung in Fallstudien.

Um dieses Ziel zu erreichen, folgt das Vorhaben einer strukturierten Herangehensweise. Zunächst werden relevante Datenquellen gesammelt und aufbereitet, um eine solide Grundlage für die Modellierung zu schaffen. Dazu gehören u.a. Daten zu erneuerbaren Energien, Stromlastgang, Speicherkapazitäten, Importpotenzial und Nichtverfügbarkeiten. Zur Datenaufbereitung und -prognose werden innovative Machine-Learning-Methoden entwickelt, welche eine präzise Vorhersage zukünftiger Energieversorgungszenarien ermöglichen. Darauf aufbauend wird ein probabilistisches Simulationsmodell zur Versorgungssicherheitsbewertung implementiert. Auf Basis des probabilistischen Modells werden Metamodelle unter Implementierung von künstlichen neuronalen Netzen entwickelt und trainiert, welche eine effiziente Berechnungen der Kennzahlen der Versorgungssicherheit ermöglichen. Die Durchführung und Analyse von Fallstudie, in der die entwickelten Modelle auf reale Problemstellungen des Energiesystems angewendet werden, runden das Projekt KIVi ab. Die Fallstudien sollen die Leistungsfähigkeit der Modelle in der Praxis demonstrieren und wertvolle Erkenntnisse für die weitere Forschung liefern.

Der Abschlussbericht des Projekts ist so strukturiert, dass er einen umfassenden Überblick über die Ergebnisse und Erkenntnisse des Forschungsprojekts bietet. Der Bericht beginnt mit einer Zusammenfassung der wichtigsten Erkenntnisse und Erfolge des Projekts. Nach einer Einführung in den Themenbereichen der Versorgungssicherheitsmodellierung und der Anwendung von Machine-Learning in der Energiesystemmodellierung in **Kapitel 1**, geht **Kapitel**

2 auf die Vorgehensweise und Ergebnisse des Projektes KIVi im Bereich der Datenaufbereitung und Implementierung von Prognosemodellen ein. **Kapitel 3** widmet der ausführlichen Vorstellung des entwickelten probabilistischen Simulationsmodells und stellt analysierte Szenarien des heutigen Energiesystems vor.

Anschließend beschreibt **Kapitel 4** die Vorgehensweise und wichtigsten Erkenntnisse im Bereich der Metamodellierung komplexer Energiesystemmodelle und schließt mit einer Bewertung und einem Methodenvergleich an unabhängigen Testszenarien. Die Ergebnisse der Anwendung des probabilistischen Simulationsmodells sowie der Metamodellierung auf reale, weitreichende energiepolitische Entscheidungen in Deutschland werden in **Kapitel 5** im Rahmen einer Fallstudie vorgestellt. **Kapitel 6** fasst die wichtigsten Erkenntnisse der Arbeiten zusammen und gibt einen Ausblick auf neue und weiterführende Fragestellungen, die sich auf Grundlage der Erkenntnisse des KIVi-Projektes ergeben. Abschließend wird dem Leser im **Kapitel 7** ein Überblick über die zahlreichen wissenschaftlichen Werke und Veröffentlichungen geboten, welche im Rahmen des Projektes KIVi entstanden sind. Die Auflistung ist in die Bereiche *Fachzeitschriftenartikel*, *Dissertationen*, *Abschlussarbeiten* sowie *Workshops und Präsentationen* auf nationalen wie internationalen Konferenzen unterteilt.

2 Datenaufbereitung und Prognosemodelle

In diesem Kapitel werden die Forschungsergebnisse zur Zeitreihenprognose der einzelnen zeitlich aufgelösten Randbedingungen, d.h. Stromlastgang, erneuerbare Energien, Speicherkapazitäten, Nichtverfügbarkeiten und Importpotential, näher vorgestellt. Der Fokus hierbei liegt auf den wichtigsten Erkenntnissen und Unterschieden der einzelnen zeitlich aufgelösten Randbedingungen. Als Bewertungskriterium der Prognose wird die mittlere betragliche relative Abweichung, i.E. Mean Absolute Percentage Error (MAPE), verwendet.

2.1 Stromlastgang

Nachfolgend wird die Leistungsfähigkeit von Methoden des Maschinellen Lernen zur Prognose des Stromlastganges Deutschlands untersucht. Zunächst zur Datenaufbereitung (*Very Short / Short Term-Forecasting*) und im Anschluss für Langzeitprognosen (*Long-Term Forecasting*).

Prognosemodelle zur Datenaufbereitung:

Im ersten Schritt soll die Fähigkeit von DL-Methoden zur Datenaufbereitung, d.h. Prognose von Lücken in unvollständigen historischen Datensätzen, bewertet werden. Um hierbei nicht von weiteren ggf. unvollständigen historischen Datensätzen abhängig zu sein, sollen diese Prognosemodelle lediglich mit der Zielgröße selbst konstruiert werden, sodass eine univariate RM-Prognosestrategie angewandt werden muss. Als Datengrundlage für die Prognose des Stromlastganges werden Daten der ENTSO-E Transparency Platform in einer stündlichen Auflösung herangezogen. Die Jahre 2014 bis 2018 dienen hierbei als Trainingsdatensatz für die unterschiedlichen Regressionsmethoden. Um die Prognosegüte der trainierten Netze zu bewerten, werden die Daten aus dem Jahr 2019 als unabhängiger Testdatensatz verwendet. Abbildung 9 zeigt den verwendeten Datensatz.




Abbildung 9: Stromlastgang Deutschlands von 2014 bis 2018 (entso-e)

Um die Vergleichbarkeit der unterschiedlichen Netz-Methodiken zu gewährleisten, werden alle nach dem gleichen Schema aufgebaut. Für die vorliegende Problemstellung werden zunächst einfache Netze mit lediglich zwei Schichten aufgebaut. Das Netz besteht also lediglich aus einer Eingabe-Schicht mit Neuronen der jeweiligen Netz-Methodik und einer Ausgabe-Schicht. Lediglich das CNN Netz besitzt aufgrund seines spezifischen Aufbaus (Convolution-, Pooling-, Flatten-Layer) mehr Schichten. Zur Prognose jedes Wertes für das Jahr 2019 werden hierbei die historischen Daten der vorherigen 60 Zeitschritte herangezogen (Lag = 60), sodass die Ergebnisse der Validierung die Prognosegüte zur Füllung von Lücken in historischen Daten widerspiegeln. Ein Vergleich des prognostizierten Verlaufs mit dem tatsächlichen Verlauf der elektrischen Gesamtlast für 2019 (= unabhängige Testdaten) wird in Abbildung 10 exemplarisch für die MLP-Netzmethodik dargestellt.




Abbildung 10: MLP Prognose Stromlastgang 2019 - Methodenbewertung „Lücken“ prognostizieren

Der Verlauf der absoluten relativen Abweichung der prognostizierten Werte für 2019 wird exemplarisch für die MLP-Netzmethodik in Abbildung 11 abgebildet.




Abbildung 11: Verlauf der relativen Abweichung 2019 (MLP-Methode - Methodenbewertung „Lücken“ prognostizieren)

Wie bereits in Abbildung 10 ersichtlich, zeigt die MLP-Netzmethode für die vorliegende Problemstellung eine gute Prognosegüte. Eine Bewertung der Prognosegüte sämtlicher betrachteter Netz-Methodiken anhand der Trainingszeit, des mittleren quadratischen Fehlers der Prognose (RMSE), des Bestimmtheitsmaßes der Korrelation zwischen Prognose- und Validierungsdaten (R^2), sowie der minimalen, mittleren und maximalen betraglichen absoluten und relativen Abweichung der Prognose von den Validierungsdaten wird in Tabelle 2 dargestellt.

Tabelle 2: Ergebnisübersicht - Methodenbewertung „Lücken“ prognostizieren

Methode	Zeit [s]	betr. abs. Abw. [MW]			betr. rel. Abw. [%]			RMSE	R^2
		min.	mittel.	max.	min.	mittel.	max.		
MLP	118	0	324	4544	0,00	0,63	10,08	473	0,9974
CNN	656	0	986	9828	0,00	1,92	22,64	1379	0,9777
VRNN	1839	0	338	3835	0,00	0,65	8,62	481	0,9973
LSTM	7133	0	353	3766	0,00	0,67	8,27	495	0,9971
GRU	4728	0	366	3599	0,00	0,69	8,77	497	0,9971

Es kann festgehalten werden, dass sämtliche Netz-Methoden mit Ausnahme des CNN gute Prognosen (im Mittel unter 0,7 % betragliche relative Abweichung) für diese triviale Problemstellung liefern. Insbesondere die MLP-Netz-Methodik zeigt aufgrund der hohen Prognosegüte und der kurzen Trainingszeit gute Ergebnisse. Die RNN-Netz-Methoden erreichen eine vergleichbare Prognosegüte, jedoch mit einer 15 bis 60 mal höheren Trainingszeit aufgrund der höheren Rechenintensität. Die vorstehenden Ergebnisse beziehen sich auf eine triviale Problemstellung, bei welcher 60 Zeitschritte vor der Lücke bekannt sind und die Lücke selbst lediglich einen Zeitschritt lang ist. Eine Problematik bei der univariaten RM-Prognosestrategie ist, dass sich bei Lücken mit mehreren Zeitschritten die Prognoseabweichung auf die Prognose der weiteren Zeitschritte auswirkt, sodass es zu einer Fehlerfortpflanzung kommt. Um

mit einer univariaten RM-Prognosestrategie weiterhin hohe Prognosegüten zu erzielen, müssen die Hyperparameter der Netze der vorliegenden Problemstellung, insbesondere dem Zeitraum der größten Lücke, angepasst werden.

Da die konkrete Problemstellung stark von dem vorliegenden unvollständigen historischen Datensatz abhängig ist, wird im zweiten Schritt die Prognosegüte bei einer univariaten RM-Prognosestrategie für eine maximal große Lücke, d.h. ein komplettes Jahr, untersucht. Hierfür muss eine größere zurückliegende Zeitspanne (8760 h) berücksichtigt werden, wodurch wesentlich komplexere Netzstrukturen mit mehreren Hidden-Layer und mehreren hundert Neuronen pro Schicht benötigt werden. Aufgrund der höheren benötigten Rechenleistung bzw. der höheren Hardwarelast erhöht sich die Trainingszeit z.B. beim MLP von 118 Sekunden, siehe Tabelle 2, auf rd. 1,5 Stunden. Dies ist auch der Grund, weshalb nur FFNN (MLP) umgesetzt wurden, da RNN-Methoden einen wesentlich höheren Anspruch an die Hardware (insbesondere an den Arbeitsspeicher) stellen und somit für diese Aufgabenstellung nur schwer umzusetzen sind. Dennoch kann mit einer univariaten RM-Prognosestrategie (MLP) eine mittlere betraglicher relative Abweichung von 5,8 % für eine Jahresprognose an den Testdaten erzielt werden.

Zusammenfassend können mit einem univariaten regressiven Lösungsansatz mit MLP eine Prognosegüte zwischen 0,6 und 5,8 % mittlere betragliche relative Abweichung in Abhängigkeit zur Größe der Datenlücke erzielt werden. Bei einer schlechteren Datengrundlage bzw. bei größeren Datenlücken sollte aufgrund der Fehlerfortpflanzung direkt auf einen multivariaten Lösungsansatz, siehe nachfolgenden Abschnitt, gewechselt werden.

Prognosemodelle zur Langzeitprognose:

Im nächsten Schritt werden univariate und multivariate Vorgehensweisen sowie DM- und RM-Prognosestrategien zur Langzeitprognose (*Long-Term Forecasting*) untersucht. Als zusätzliche Features werden bei der multivariaten Vorgehensweise kalendarische Informationen und flächengewichtete Wetterdaten basierend auf dem MERRA-2 Datensatz (QUELLE) verwendet. Da der MERRA-2 Datensatz für Deutschland ab 2019 größere Datenlücken aufweist und die Analyse nicht von prognostizierten Daten beeinflusst werden soll, werden im nachfolgenden die Jahre 2014 bis einschließlich 2017 als Trainingsdatensatz und das Jahr 2018 als unabhängiger Testdatensatz verwendet.

In Abbildung 12 werden die minimale, die mittlere bzw. der MAPE-Wert (*Mean Absolute Percentage Error*) und die maximale relative Betrags-Abweichung für das Prognosejahr 2018 unterschiedlicher Methoden des Maschinellen Lernens, prinzipieller Vorgehensweisen (univariat/multivariat) und unterschiedlicher Prognosestrategien (DM/RM) miteinander verglichen. Zusätzlich zu den in Kapitel 1.2.3 eingeführten Regressionsmethoden wird *Fast Fourier Transform Forecasting* (FFTF) und *Auto-Regressive Integrated Moving Average Methods* (ARIMA/SARIMA etc.) betrachtet. Aufgrund der hohen Anzahl an Datenpunkten wird bei der Verwendung der GPR-Methodik die sogenannte *Sparse Gaussian Process Regression* (SGPR) angewendet. Bei dieser Methode wird die Anzahl der zu berücksichtigenden Datenpunkte reduziert, da die herkömmliche GPR Schwierigkeiten hat, große Datenmengen zu verarbeiten. Als Methode aus dem Bereich der Entscheidungsbäume wird die Ensemble-Methode, *eXtreme Gradient Boosting* (XGBoost) verwendet, welche die Methodik der Entscheidungsbäume mit Gradient Boosting kombiniert.




Abbildung 12: Vergleich von ausgewählten Methoden am Bsp. Stromlastgang

Ein methodischer Unterschied ist, dass bei multivariater Vorgehensweise mit RM-Prognosestrategie basierend auf Wetterszenarien/-prognosen und ohne Verwendung der Zielgröße als Einflussgröße die Sequenzlänge gegenüber einer univariaten Vorgehensweise (8760 h) für eine hochaufgelöste Langzeitprognose drastisch reduziert werden kann. Eine Erhöhung der Sequenzlänge hat allerdings auch bei der multivariaten Vorgehensweise mit einer RM-Prognosestrategie einen positiven Einfluss auf die Prognosegüte. Beispielsweise verbessert sich der MAPE-Wert bei einer Erhöhung von 24 auf 168 Zeitschritte von rd. 3,1 % auf rd. 2,9 % (GRU). Eine Erhöhung der Zeitschritte führt bei einer multivariaten Vorgehensweise aufgrund der Anzahl an *Lag-Features* jedoch zu einer wesentlich stärkeren Erhöhung der Samples. Dies führt wiederum zu einem höheren Anspruch an die Netzstruktur sowie zu einer stärkeren Erhöhung der Trainingszeit und der Hardwareauslastung. Beim Methodenvergleich der multivariaten Vorgehensweise mit RM-Prognosestrategie wird deutlich, dass die GRU Methode die beste Prognosegüte erzielt. Anzumerken ist noch, dass bei der LSTM-Methode eine Problematik (*Exploding Gradients*) auftrat, welche für die vorliegende Problemstellung nicht behoben werden konnte. Dies verhindert eine weitere Erhöhung der Sequenzlänge (>24 h) und somit eine Steigerung der Prognosegüte.

Ein direkter Vergleich der Prognosegüte zwischen univariater und multivariater Vorgehensweise kann nicht gezogen werden, da die multivariate Vorgehensweise im realen Anwendungsfall auf zusätzlich prognostizierte Einflussgrößen bzw. Szenarien (hier Wetterdaten) angewiesen ist, während die univariate Vorgehensweise bei den vorstehenden Ergebnissen bereits selbstprognostizierte Daten der Zielgröße verwendet. Hinsichtlich der Prognosegüte, Laufzeit und Hardwareauslastung hat sich eine multivariate DM-Prognosestrategie für Langzeitprognosen bewährt. Im Gegensatz zu einem direkten Ansatz wird bei rekursiven Prognoseansätzen eine Zeitsequenz der letzten Zeitschritte der Zielgröße (univariat) oder mehrerer Einflussgrößen und ggf. zuzüglich der Zielgröße (multivariat) zur Prognose verwendet. Wird

für diese Zeitsequenz auch die Zielgröße verwendet, kommt es zu einer Fehlerfortpflanzung des Prognosefehlers. Dies ist insbesondere für die benötigten hochaufgelösten Langzeitprognosen (*Long-Term Forecasting*) aufgrund der hohen Anzahl an zu prognostizierenden Zeitschritten kritisch. Darüber hinaus weist ein rekursiver Ansatz aufgrund der großen Datenmenge, z.B. beim Training neuronaler Netze, signifikant höhere Laufzeit und Hardwareauslastung auf.

Die Ergebnisse zeigen auf, dass nicht nur auf einen rekursiven Prognoseansatz verzichtet werden kann, sondern auch, dass die leistungsschwächeren MLP-Netze durch eine angepasste Verarbeitung der kalendarischen Informationen und durch eine verbesserte Netzstruktur/ Hyperparameteroptimierung für die vorliegenden Anwendungsfälle ausreichend sein können (MAPE = 1,9 %) und die Verwendung von RNN-Netzen, welche ebenfalls eine signifikant höhere Trainingszeit und Hardwareauslastung aufweisen, nicht notwendig ist. Auch die klassische GPR mit modernen Methoden (SGPR) erzielte ein konkurrenzfähiges Ergebnis (MAPE = 2,0 %) und bietet zudem eine bessere Interpretierbarkeit und mehr Analysemöglichkeiten. Ferner wurden ebenfalls mit XGBoost gute Ergebnisse (MAPE = 2,4 %) erzielt. Im Vergleich zu MLP und GPR erzielen diese bezüglich der Prognosegüte zwar schlechtere Ergebnisse, jedoch ist die Anwendung leichter und erfordert weniger Expertise. Die vorstehenden Ergebnisse wurden auf der ENERDAY 2022 - 16th International Conference on Energy Economics and Technology Konferenz vorgestellt.

2.2 Erneuerbare Energien

Neben der Nachfrageseite gibt es auch auf der Angebotsseite Unsicherheiten, die insbesondere durch den Ausbau der erneuerbaren Energien bedingt sind. Dies stellt eine kritische Planungsgrößen dar, da sowohl Situationen der Über- als auch der Unterversorgung möglich sind. Im Rahmen der Bewertung der Stromversorgungssicherheit ist die Unterversorgung von besonderer Relevanz [34]. Die Einbeziehung von Überversorgungssituationen in die Analyse wird jedoch zukünftig umso wichtiger, je mehr Speicher im System diese Energie aufnehmen und in Zeiten der Unterversorgung wieder zur Verfügung stellen können [58]. Ähnlich wie bei der Prognose von Stromlastprofilen kann der Zeithorizont der Prognose als erste Unterscheidung der Anwendungsbereiche genutzt werden:

Tabelle 3: Methoden und Anwendungen der Erzeugungsprognose [40]

Zeithorizont	Methoden	Wichtige Anwendungen
5 - 60 min. im Voraus	Sehr kurzfristige Vorhersage	Regulierung, Echtzeit-Dispatch, Handel, Market-clearing
1 - 6 Stunden im Voraus	Kurzfristige Prognose	Einsatzplanung, Lastverfolgung, Engpassmanagement
Tag(e) im Voraus	Mittelfristige Prognose	Einsatzplanung, Reserveanforderung, Handel, Engpassmanagement
Wochen oder mehr im Voraus	Langfristige Prognose	Planung von Ressourceninvestitionen (Erzeugung, Netz), Notfallanalyse, Wartung

Für das Anwendungsporträt im Projekt KIVi ist wiederum die Langzeitprognose der relevante Zeithorizont. Erneuerbare Einspeisepprofile kombinieren die Verfügbarkeit des Kraftwerks mit einer Kapazitätsgutschrift, die auf Wetterprognosen basiert [58]. Auf die Vorhersage von Nichtverfügbarkeiten wird in Abschnitt 2.4 näher eingegangen. Prognosen von erneuerbaren Einspeiseprofilen können sich auf die rein wetterabhängigen Aspekte oder eine Kombination aus beiden konzentrieren.

Vorhersagedaten: Einspeisepprofile für erneuerbare Energien werden als Zeitreihen mit unterschiedlicher zeitlicher Auflösung angegeben. Ähnlich wie bei den Stromlastprofilen werden sie als aggregierte Informationen zur Verfügung gestellt, die z.B. Minuten- oder Stundenmittelwerte liefern [59]. Für die Bewertung der Stromversorgungssicherheit sind neben den Durchschnittswerten im Gegensatz zu den Stromlastprofilen nicht die Maximal-, sondern die Minimalwerte von Interesse, um eine robuste Analyse durchführen zu können, die auch Extremereignisse abbilden kann. Erneuerbare Einspeisepprofile können unterschiedlichen Aggregationsstufen unterliegen:

- Technologische Aggregation: Z.B. Aggregation oder Disaggregation von Aufdach-PV und Freiflächen-PV
- Regionale Aggregation: Keine regionale Differenzierung, einschließlich regionaler Identifikatoren oder pro Einheit
- Zeitliche Aggregation: Zeitreihendaten in sub-stündlicher, stündlicher, täglicher oder wöchentlicher Auflösung

Auswahl der Merkmale: Die wichtigsten Merkmale, die (aggregierte) Einspeisepprofile für erneuerbare Energien beeinflussen, sind historische meteorologische Daten, numerische Wettervorhersagen (NWP) und Informationen über die Umgebung, um die Auswirkungen von Schatten und Windschatten abzuschätzen. [40,43]




Abbildung 13: Wissenschaftliche Zeitschriftenartikel über Einspeiseprognosen für erneuerbare Energien in energiebezogenen Journals der Scopus-Datenbank von 2010 bis 2020, kategorisiert nach KI-basierten Methoden [40]

Vorhersagemodelle: Abbildung 13 zeigt die Ergebnisse der systematischen Literaturrecherche zu Einspeiseprognosen für erneuerbare Energien. Ähnlich wie bei Studien zur Vorhersage von Stromlastprofilen sind FFNNs auch bei der Vorhersage von Zeitreihen zur Einspeisung erneuerbarer Energien die am häufigsten verwendete KI-Methode. CNNs und RNNs haben seit 2018 drastisch an Popularität gewonnen. Während Support Vector Machines eine konstante Anzahl von ~20 Veröffentlichungen aufweisen, werden andere Methoden wie Entscheidungsbäume, Bayes'sche Modelle oder Ensemble-Methoden noch nicht häufig für die Vorhersage von Zeitreihen der erneuerbaren Einspeisung verwendet. [40,43]

2.3 Speicherkapazitäten

In traditionellen Energiesystemen waren Speichersysteme hauptsächlich große zentrale Einheiten wie Pumpspeicherkraftwerke. Die Dezentralisierung der Energieversorgung erhöht die Anzahl und Vielfalt der Speichereinrichtungen erheblich [60]. Außerdem könnten in Zukunft neue zentrale Speichertechnologien zum Einsatz kommen, wie z.B. elektrische Druckluftspeicher (CAES) [61]. Kleine und große Speichereinheiten werden auf den Energiemärkten unterschiedlich operieren, da große Einheiten einen Einfluss auf den Marktpreis haben können (Preissetzer), während kleine Einheiten dies nicht tun (Preisnehmer) [62]. Die steigende Anzahl und Kapazität von Energiespeichern sowie deren unterschiedliche Betriebsstrategien, der Rückgang der steuerbaren Kraftwerke und der Ausbau der volatilen erneuerbaren Energien erhöhen die Bedeutung von Speichern für die Stromversorgungssicherheit [63]. Daher wird die Vorhersage des Speicherbetriebs immer wichtiger. Im Gegensatz zu thermischen und erneuerbaren Kraftwerken arbeiten Speichersysteme nicht unbedingt im Einklang mit

übergeordneten Systemzielen wie der Versorgungssicherheit. Betreiber von Speichersystemen können aus eigennützigen Gründen gespeicherte Energie zurückhalten oder zusätzliche Stromnachfrage erzeugen. Zu den Gründen hierfür gehören Arbitragemöglichkeiten, die Verlängerung der Lebensdauer ihrer Anlagen oder die Maximierung des Eigenverbrauchs [64]. Große Energiesystemmodelle, die neben Kraftwerken auch Speicher einbeziehen und die Gesamtsystemkosten minimieren, haben Schwierigkeiten, diese Verhaltensweisen endogen darzustellen [65]. Um dieses Problem zu überwinden, können Ansätze zur Modellkopplung angewendet werden. Teilmodelle, die die Perspektive der Speicherbetreiber einnehmen, können dann den Speicherbetrieb abbilden, der z.B. iterativ in ein größeres Systemmodell eingespeist wird. Solche Teilmodelle könnten wiederum Methoden zur Kostenminimierung anwenden oder den Speicherbetrieb mit Hilfe von Methoden des maschinellen Lernens abbilden, die ein solches Verhalten aus historischen Daten lernen. [40,43]

Vorhersagedaten: Der Speicherbetrieb wird letztlich in der gleichen zeitlichen Auflösung benötigt wie andere zeitliche Eingangsdaten, die für die Bewertung der Stromversorgungssicherheit verwendet werden. Die Daten zum Speicherbetrieb unterliegen verschiedenen Aggregationsstufen:

- Technologische Aggregation: Gesamter Speichereinsatz und Ladezustand (SoC), pro Speichertechnologie oder pro Speichereinheit
- Speicherspezifische Informationen: Speicherabfertigung und/oder SoC
- Regionale Aggregation: Keine regionale Differenzierung oder Einbeziehung regionaler Identifikatoren
- Zeitliche Aggregation: Zeitreihendaten in substündlicher, stündlicher, täglicher oder wöchentlicher Auflösung

Die Informationen über den Speicherbetrieb können auf historischen Daten oder Simulationen beruhen. Scapino et al. [66] beispielsweise verwenden ein physikalisch basiertes Modell, um ein Speichersystem zu simulieren und die Prognosedaten für das Vorhersagemodell zu generieren.

Auswahl der Merkmale: Die wichtigsten Merkmale, die den Speicherbetrieb beeinflussen, sind neben technischen Merkmalen Preis- und andere Marktinformationen, Wetterdaten sowie Last- und Erzeugungsdaten. Die von Priesmann et al. (2021) aufgelisteten Studien verwenden nicht ausschließlich Methoden des maschinellen Lernens, da die Anzahl der in der Literaturrecherche gefundenen Studien zum Zeitpunkt der Recherche zu gering ist [40]. Wir gehen davon aus, dass die aufgelisteten Merkmale unabhängig vom methodischen Ansatz als guter Ausgangspunkt für die Konstruktion von auf maschinellem Lernen basierenden Modellen dienen können. [40,43]

Vorhersagemodelle: Abbildung 14 zeigt die Ergebnisse der systematischen Literaturrecherche zur Vorhersage des Speicherbetriebs.




Abbildung 14: Wissenschaftliche Zeitschriftenartikel zur Vorhersage des Speicherverhaltens in energiebezogenen Journals in der Scopus-Datenbank von 2010 bis 2020, kategorisiert nach KI-basierter Methodik [40]

Der Bereich der Vorhersagemodelle für den Speicherbetrieb mit Hilfe des maschinellen Lernens ist noch nicht in großem Umfang etabliert, hat aber im Jahr 2020 eine deutliche Erweiterung erfahren. Neuronale Netze sind die am häufigsten angewandte Methode, aber auch Support Vector Machines, Gaussian Process Regression und Entscheidungsbäume werden verwendet. Auf dem Gebiet der neuronalen Netze zeichnet sich ein Trend zu RNNs ab, auch wenn dies in den Zahlen der Veröffentlichungen noch nicht deutlich sichtbar ist. Wang et al. [67] entwickelten ein Vorhersagemodell für dezentrale elektrische Heizungsspeichersysteme. Sie stellen fest, dass ihr korrelationsbasiertes LSTM-Modell besser abschneidet als Support-Vektor-Maschinen und reguläre RNN-Modelle. Xiao et al. kommen zu einer ähnlichen Schlussfolgerung, wenn sie mehrere Methoden für das Verhaltenslernen in Mikronetzen vergleichen. Sie postulieren, dass sich LSTM-Modelle am besten für Mikronetze eignen, die Speichersysteme umfassen [68].

2.4 Nichtverfügbarkeiten

Eine große Unsicherheit bei der Bewertung der Stromversorgungssicherheit ist die Verfügbarkeit von Erzeugungskapazitäten und Netzkomponenten. Komponenten im Energiesystem können aufgrund von geplanten und ungeplanten Ausfällen nicht verfügbar sein [34]. Geplante Nichtverfügbarkeiten sind im Voraus bekannt und sind in der Regel auf geplante (z. B. jährliche) Wartungsarbeiten zurückzuführen. Ungeplante Nichtverfügbarkeiten sind nicht im

Voraus bekannt, unterliegen einer viel zufälligeren Verteilung als geplante Nichtverfügbarkeiten und können auf Fehlfunktionen oder unkontrollierbare externe Faktoren wie extreme Wetterbedingungen zurückzuführen sein. Beide Arten von Ereignissen haben einen großen Einfluss auf die Versorgungssicherheit [69]. Aufgrund ihrer unterschiedlichen Verteilung und Einflussfaktoren werden sie in der Regel getrennt modelliert und prognostiziert [70]. Der Anwendungsbereich der Verfügbarkeit von Kraftwerken für auf maschinellem Lernen basierende Methoden ist daher zweigeteilt. Bei geplanter Nichtverfügbarkeit müssen die geplanten Wartungszyklen vorhergesagt werden [34]. Erkenntnisse aus der vorausschauenden Instandhaltung können übertragen werden, um die Vorhersage von Wartungsplänen zu verbessern [71]. Im Gegensatz dazu müssen bei ungeplanter Nichtverfügbarkeit Faktoren wie die komplexe Thermodynamik und die Versorgungssicherheit von Brennstoffen modelliert werden [72]. Dies stellt grundlegend andere Anforderungen an prädiktive Modelle. [40,43]

Eine weitere Herausforderung, die sich aus der systemischen Sichtweise bei der Bewertung der Stromversorgungssicherheit ergibt, ist, dass keine weiteren Betriebsdaten von bestimmten Standorten vorliegen. Dies ist darauf zurückzuführen, dass die Gesamtheit der Kraftwerke mit verschiedenen Betreibern und an verschiedenen Standorten abgebildet werden muss. Prognosemodelle müssen sich daher ausschließlich auf externe Faktoren wie z.B. die Wetterbedingungen stützen, die überwacht und vorhergesagt werden können. Schließlich muss zwischen der Modellierung der Nichtverfügbarkeit von Komponenten unabhängig oder (1) unter Berücksichtigung von Common-Mode-Situationen und (2) unter Berücksichtigung der Zeitabhängigkeit unterschieden werden. [40,43]

Vorhersagedaten: Die Nichtverfügbarkeit von Komponenten kann als binäre Information, als mehrere diskrete Zustände oder als kontinuierliche Verfügbarkeitsstufen vorliegen. Binäre Daten geben an, ob die Komponente verfügbar ist oder nicht, während diskrete und kontinuierliche Daten zusätzlich den Anteil der nicht verfügbaren Kapazität anzeigen. Die Daten zur Nichtverfügbarkeit unterliegen verschiedenen Aggregationsstufen:

- Technologische Aggregation: Gesamtkapazität, Kapazität pro Erzeugungstechnologie oder Kapazität pro Erzeugungseinheit
- Regionale Aggregation: Keine regionale Differenzierung oder Einbeziehung regionaler Identifikatoren
- Zeitliche Aggregation: Jährliche Daten (Verfügbarkeitsfaktor), Daten für bestimmte Zeitpunkte (z. B. während der jährlichen Spitzenlast) oder Zeitreihendaten (z. B. stündlich aufgelöst)

Auswahl der Merkmale: Wir gehen davon aus, dass die wichtigsten Merkmale, die die Verfügbarkeit von Erzeugungskapazitäten beeinflussen, kalendarische Informationen, technologiespezifische Daten, Wetter- und weitere Umweltdaten, Preisdaten und Lastdaten sind. Priesmann et al. (2021) zeigt eine Auswahl von Studien zur (Nicht-)Verfügbarkeitsprognose für thermische Kraftwerke und die in den Prognosemodellen verwendeten Merkmale [40]. Die aufgeführten Studien verwenden nicht ausschließlich Methoden des maschinellen Lernens, da die Anzahl der in der Literaturrecherche gefundenen Studien zum Zeitpunkt der Recherche zu gering ist. Wir gehen davon aus, dass die aufgeführten Merkmale unabhängig vom methodischen Ansatz als guter Ausgangspunkt für die Konstruktion von auf maschinellem

Lernen basierenden Modellen dienen können. Interessanterweise sind Preisdaten (Termin- oder Kassapreise) als erklärende Variablen in der Literatur nicht zu finden. [40,43]

Vorhersagemodelle: Abbildung 15 zeigt die Ergebnisse der systematischen Literaturrecherche zur Nichtverfügbarkeit von Erzeugungskapazitäten.




Abbildung 15: Wissenschaftliche Zeitschriftenartikel zur Vorhersage der (Nicht-)Verfügbarkeiten von Kraftwerken in energiebezogenen Journals in der Scopus-Datenbank von 2010 bis 2020, kategorisiert nach KI-basierter Methodik [40]

Der Bereich der Vorhersagemodelle für die (Nicht-)Verfügbarkeit von Kraftwerken unter Verwendung von maschinellem Lernen ist noch nicht in großem Umfang etabliert. Neuronale Netze sind die am häufigsten angewandte Methode, und ihre Zahl ist in den letzten Jahren gestiegen. Support-Vektor-Maschinen und Bayes'sche Modelle werden in wenigen Arbeiten verwendet. Betrachtet man die wenigen verfügbaren Studien, so stützen sich die meisten zitierten Arbeiten auf Sensordaten. Da Sensordaten in der Regel für die Vorhersage einzelner Kraftwerksausfälle verwendet werden, kommen wir zu dem Schluss, dass die Anwendung von auf maschinellem Lernen basierenden Methoden zur Vorhersage der (Nicht-)Verfügbarkeit von Kraftwerken auf Systemebene eine große Forschungslücke darstellt. [40,43]

2.5 Importpotential

Im Nachfolgenden werden ausgewählte ML-Methoden (MLP, LSTM, XGBoost und SGPR), welche bereits bei den vorigen Randbedingungen gute Prognosegüten erzielten, auf die Problemstellung der Prognose des Importpotentials angewendet. Der Trainingsdatensatz umfasst die Jahre 2006 bis 2013 und beinhaltet als *Features* Wetterdaten und den Lastgang

Deutschland. Zur Bewertung der Prognosegüte wird der Zeitraum von 2014 bis 2015 als unabhängiger Testdatensatz verwendet. Die Anzahl der Daten, d.h. die verwendeten *Features*, wurde variiert und die Hyperparameter entsprechend optimiert. Um die Auswahl geeigneter Modelle zu beschleunigen und Hyperparameteranpassungen bereits nach relativ kurzen Trainingszeiten bewerten zu können, wird auf das *Single Holdout-Verfahren* zurückgegriffen. Dabei werden die Trainingsdaten nicht, wie eigentlich üblich in Trainings- und Validierungsdaten getrennt, sondern die Testdaten werden gleich während des Trainings zur Verifikation genutzt. Hierdurch entfällt jedoch die Möglichkeit die Prognosegüte des Prognosemodells anhand von unabhängigen Daten zu bewerten. Zusätzlich besteht ein hohes Risiko des Overfittings an den Testdaten. Auch wenn sich diese Methode nicht für ein finales Training von Modellen eignet, konnte so eine effiziente Abschätzung der Performance der unterschiedlichen Methoden vorgenommen werden.

Zunächst werden die Ergebnisse mit der Single-Holdout-Methode der DL-Methoden (MLP und LSTM) mit 100/25 Epochen, der XGBoost Methode mit 1500 Entscheidungsbäumen und der SGPR untersucht. Auf Basis dieser Ergebnisse wurden die fünf vielversprechendsten Prognosemodelle ausgewählt. Dargestellt werden die Ergebnisse des *Single-Holdout* in Tabelle 4.

Tabelle 4: Zusammengefasste Ergebnisse des Single-Holdout

Methode	MAPE in %
Feed-Forward-Network	3,46
Long Short-Term Memory	3,32
Extreme Gradient Boosting	2,63
Sparse Gauss Process	5,21

Die performantesten Modelle werden im Anschluss mit dem *Time-Series-Split* (TSS) trainiert. Hierbei werden die Epochenzahl auf 25 für die KNN gesenkt, da hier durch den TSS vier Datensätze vorliegen und sich so in Summe wieder eine Epochenzahl von 100 ergibt. Die Ergebnisse dieses ersten TSS sind in Tabelle 5 dargestellt. Zu beachten ist, dass es sich hierbei um die erste belastbare Prognosegüte handelt, da der erste Blindtest erst hier durchgeführt wird.

Tabelle 5: Ergebnisse der Methoden mit Time-Series-Split

Methode	MAPE in %
Feed-Forward-Network	3,56
Long Short-Term Memory	3,74
Extreme Gradient Boosting	2,71

Im Anschluss findet eine weitere Selektion auf nur noch zwei Modelle pro Methode bei den KNN statt. Diese werden dann mit einer deutlich höheren Epochenzahl von 250 pro Datensatz (bzw. 1000 in Summe) final mit dem TSS trainiert und an den Testdaten evaluiert. Bei

der XGBoost Methode wurde aufgrund der sehr kurzen Trainingszeit an nur einem Modell eine manuelle Grid Search Hyperparameteroptimierung durchgeführt. Auch hier fand nun ein erneutes Training mit deutlich erhöhter Anzahl an Entscheidungsbäumen statt, 15.000 statt 1.500. Die finalen Ergebnisse der Prognosegüte sind in Tabelle 6 dargestellt.

Tabelle 6: Finales Ergebnisse nach langem Training mit Time-Series-Split

Methode	MAPE in %
Feed-Forward-Network	3,51
Long Short-Term Memory	3,65
Extreme Gradient Boosting	2,67

Die Methode zur Ermittlung von geeigneten Modellen in Kombination mit Variation von Features und Hyperparametern über den *Single-Holdout* hat sich bewährt. Die Modelle, die in dieser ersten Iteration gute Ergebnisse erzielen konnten, können sich auch im weiteren Verlauf der Trainings durchsetzen und mit zunehmenden Trainingsepochen eine höhere Prognosegüte erreichen.

Die Verbesserung des MAPE-Werts beim Training mit den TSS verdeutlicht, dass diese Art der Kreuzvalidierung sich sehr gut für die Zeitreihenprognose eignet und das Risiko von *Overfitting* effizient reduziert. Zudem ermöglicht es auch bei begrenzten historischen Daten ein erfolgreiches Trainieren des Prognosemodells.

Die Prognosegüte des XGBoost Modells kann mit einem MAPE-Wert von 2,67 % bei stündlicher Prognose über zwei Jahre als präzise bezeichnet werden und zeigt deutlich das Potential des Maschinellen Lernens zur Erstellung von Zeitreihenprognosen. Beim FNN (MAPE von 3,51 %) sind unter Zuhilfenahme eines *Lags* noch Optimierungen denkbar. Dabei wird der zeitliche Betrachtungsraum bei jedem einzelnen Schritt des Trainings auf mehrere Stunden erhöht, wodurch unter Einsatz von mehr Rechenleistung Zusammenhänge von dem Modell besser interpretiert werden können. Das RNN in Form des LSTM erreichte einen MAPE von 3,65 % und schnitt damit erstaunlicherweise schlechter als das einfacher aufgebaute FNN ab. Möglicherweise gibt es auch hier noch Verbesserungspotenzial. Alternativ könnten andere RNN Methoden betrachtet werden. Das SGP besitzt viele Konfigurationsmöglichkeiten, was nach den vorgenommenen ersten Versuchen mit einem MAPE-Wert von 5,2 % ebenfalls noch sehr viel Spielraum zur Optimierung des Modells erahnen lässt.

3 Versorgungssicherheitsmodellierung

3.1 Probabilistisches Simulationsmodell

Im folgenden Abschnitt soll das Vorgehen der probabilistischen Versorgungssicherheitsmodellierung im Projekt KIVI anhand von **fünf Unterabschnitten** erläutert werden. Zunächst wird der Ansatz zur Modellierung der Verfügbarkeit von einzelnen Kraftwerksblöcken erläutert. Anschließend wird der mathematische Ansatz der rekursiven Faltung für die Modellierung eines Systems aus einer Vielzahl von Kraftwerksblöcken vorgestellt. Abschnitt drei bietet eine Zusammenfassung der Methoden zur Simulation der wetterabhängigen Stromnachfrage, der Einspeisung von erneuerbaren Energien sowie der Residuallast. Anschließend wird in Abschnitt vier eine Modellerweiterung vorgestellt, welche es ermöglicht, Beiträge aus benachbarten Ländern abzubilden. Schließlich demonstrieren Abschnitt fünf das Zusammenspiel aller Komponenten zur Berechnung von Kennzahlen für die Bewertung der Versorgungssicherheit mit Elektrizität.

Modellierung einzelner Kraftwerksblöcke

Um den Anteil der zu einem Zeitpunkt verfügbaren Kraftwerkskapazitäten im realen Energiesystem abzubilden, wird eine stochastische Verteilung der Verfügbarkeitswahrscheinlichkeiten angenähert. Diese Verteilung wird im Folgenden unter der realistischen Annahme abgeleitet, dass jeder einzelne Block des thermischen, steuerbaren (d.h. frei disponierbaren) Kraftwerksportfolios über zwei mögliche Zustände verfügt: vollständige Verfügbarkeit oder Nichtverfügbarkeit. Somit werden hier teilweise Verfügbarkeiten vernachlässigt. Da die Modellierung auf einzelnen Kraftwerksblöcken als kleinste Einheiten beruht, scheint diese Annahme gerechtfertigt. Unter der zusätzlichen Annahme stochastischer Unabhängigkeit der Nichtverfügbarkeitswahrscheinlichkeiten unterschiedlicher Blöcke folgt somit jeder Kraftwerksblock unabhängig von allen anderen Blöcken einer diskreten Bernoulli-Verteilung. Der Zustand der Nichtverfügbarkeit für einen Kraftwerksblock mit Index i zu einem gegebenen Zeitpunkt t tritt mit der Wahrscheinlichkeit $p_i(t)$ ein. Entsprechend ist die Wahrscheinlichkeit, dass der Block voll verfügbar ist, durch die Gegenwahrscheinlichkeit $1 - p_i(t)$ gegeben. Dieser Zusammenhang ist in Abbildung 16 dargestellt. [34]




Abbildung 16: Diskrete Bernoulli-Verteilung der Nichtverfügbarkeiten eines einzelnen Kraftwerksblocks

Bei der Bestimmung der Nichtverfügbarkeitswahrscheinlichkeit sind die beiden Kategorien der geplanten und ungeplanten Nichtverfügbarkeit zu unterscheiden. Eine geplante Nichtver-

f ugbarkeit ist nach VGB [73] dadurch definiert, dass Beginn und Dauer mindestens vier Wochen vor ihrem Auftreten feststehen. Ist die Vorlaufzeit k rzer, liegt eine ungeplante Nichtverf ugbarkeit vor. Erstere werden vornehmlich durch Wartungsarbeiten verursacht, w hrend letztere am h ufigsten durch St rungen oder Ausf lle verursacht werden. Im Folgenden wird die Wahrscheinlichkeit einer geplanten Nichtverf ugbarkeit als $q_i(t)$ bezeichnet. Weiterhin wird die Wahrscheinlichkeit einer ungeplanten Nichtverf ugbarkeit als $r_i(t)$ definiert. [34]




Abbildung 17: Geplante und nicht geplante Nichtverf ugbarkeit eines Kraftwerksblocks

Gem   Abbildung 17 ergibt sich die Wahrscheinlichkeit f r die Nichtverf ugbarkeit eines Kraftwerksblocks $p_i(t)$ als kumulierte Wahrscheinlichkeit f r die geplante Nichtverf ugbarkeit und die ungeplante Nichtverf ugbarkeit. Sie kann wie folgt berechnet werden:

$$p_i(t) = q_i(t) + (1 - q_i(t)) * r_i(t) = q_i(t) + r_i(t) - q_i(t) * r_i(t)$$

Die Wahrscheinlichkeit f r eine geplante Nichtverf ugbarkeit wird durch das Auftreten von Wartungsarbeiten bestimmt. Die Wartungsintervalle der verschiedenen Kraftwerkstypen und damit die Wahrscheinlichkeit f r geplante Nichtverf ugbarkeiten folgen einem zeitlichen Verlauf mit ausgepr gter saisonaler Charakteristik. Dies l sst sich aus der Analyse der auf der Transparency Plattform der EEX [74] berichteten Ausf lle schließen. F r die H ufigkeit ungeplanter Nichtverf ugbarkeiten kann jedoch keine Zeitabh ngigkeit identifiziert bzw. auf Basis des genannten Datensatzes statistisch abgesichert werden. Dies f hrt zu dem Schluss, dass die Wahrscheinlichkeit ungeplanter Nichtverf ugbarkeiten $r_i(t)$ nicht zeitabh ngig ist und somit als $r_i(t) \approx r_i \approx konst$ modelliert werden kann. Aus diesem Grund sind Jahresmittelwerte die statistisch besten Sch tzungen. [39]

Um eine m glichst breite Datenbasis f r die Ableitung der Nichtverf ugbarkeitswahrscheinlichkeiten abzuleiten, wurden zwei Datens tze kombiniert: Ver ffentlichungen auf der Transparenzplattform der EEX [74] und j hrliche durchschnittliche Ausfallwahrscheinlichkeiten, ver ffentlicht von VGB e.V. [73]. Der VGB e.V. stellt einen umfassenden Datensatz, allerdings werden nur Jahresdurchschnittswerte f r geplante und ungeplante Ausf lle dokumentiert. Im Gegensatz dazu ver ffentlicht die EEX ihre Daten als Zeitreihen mit Zeitstempeln und hoher zeitlicher Aufl sung aber mit geringerer Abdeckungsrate. Ausgehend von der Datenlage und den Erkenntnissen  ber die Saisonalit t der geplanten Nichtverf ugbarkeit wurde folgender Ansatz gew hlt, um das bestm gliche Ergebnis zu erzielen: Aufgrund des umfangreicheren Datensatzes und der vernachl ssigbaren Saisonalit t werden die Jahresmittel-

werte nach VGB e.V. [73] für die ungeplanten Nichtverfügbarkeiten verwendet. Zur Darstellung der Zeitabhängigkeit der geplanten Nichtverfügbarkeit werden Zeitreihendaten der EEX [74] verwendet und mit den Jahresmittelwerten nach VGB skaliert. Des Weiteren wurden die Jahreskurven mittels einer Sliding-Window-Technik aggregiert, um repräsentative Kurvenverläufe zu generieren. Da die EEX [30] nicht für alle Kraftwerkstypen ausreichende Daten veröffentlicht, werden die vom VGB e.V. [29] ausgewiesenen Jahresmittelwerte der geplanten Nichtverfügbarkeiten herangezogen. Dieses Verfahren ist auf Kraftwerkstypen beschränkt, die nur einen geringen Anteil an der installierten Leistung des Kraftwerksparks in Deutschland ausmachen. [39]

Modellierung eines Systems aus Kraftwerksblöcken

Nachdem im vorherigen Absatz die Herleitung der zeitabhängigen Ausfallwahrscheinlichkeit eines einzelnen thermischen, steuerbaren Kraftwerksblocks gezeigt wurde, wird diese Betrachtung nun um den Zusammenschluss einer großen Anzahl von Einzelblöcken zu einem System erweitert. Das nachfolgende Beispiel für ein System mit $N = 5$ Kraftwerksblöcken veranschaulicht die Zusammenführung der einzelnen Zustände der Kraftwerksblöcke hin zu Systemzuständen, denen jeweils eine verfügbare Gesamtkapazität an thermischen Kraftwerksblöcken sowie eine Eintrittswahrscheinlichkeit dieses Systemzustands zugeordnet ist (vgl. Abbildung 18).





Abbildung 18: Beispielhafte Darstellung möglicher Systemzustände bei insgesamt drei Kraftwerksblöcken

Die verfügbare Kapazität in einem Systemzustand j ergibt sich aus der Summe der installierten Leistungen der im jeweiligen Zustand verfügbaren Kraftwerksblöcke. Die zugehörige Eintrittswahrscheinlichkeit des Systemzustands j ergibt sich basierend auf der hier angenommenen stochastischen Unabhängigkeit der Verfügbarkeitswahrscheinlichkeiten der einzelnen Blöcke als Produkt aus den Einzelwahrscheinlichkeiten entlang des Zustandspfades.

Durch die getroffene Annahme, dass jeder Block des steuerbaren Kraftwerksportfolios zwei diskrete Zustände annehmen kann, ergeben sich bei einer Abstraktion des Systems auf n Kraftwerksblöcke insgesamt 2^n mögliche Systemzustände. Für die Bewertung der Versorgungssicherheit muss die Wahrscheinlichkeit berechnet werden, dass eine bestimmte Kapazität verfügbar ist. Da eine direkte Berechnung aufgrund der hohen Anzahl möglicher Zustände rechnerisch nicht möglich ist, wird im vorliegenden Modellierungsansatz das mathematische Konzept der rekursiven Faltung verwendet. Für ein Energiesystem mit ~ 600 Kraftwerksblöcken ergeben sich insgesamt $2^{600} \approx 4,15 \cdot 10^{180}$ Systemzustände [39]. Bei der rekursiven Faltung wird die Berechnung rekursiv erweitert, indem ein Kraftwerksblock nach dem anderen hinzugefügt wird. Die Wahrscheinlichkeit $Pr_i(P_A > P)$, mit der die Ausfallleistung P_A (d.h. die Summe der Nichtverfügbarkeiten) einen gegebenen Schwellenwert P in einem System mit i Kraftwerksblöcken überschreitet, kann basierend auf einem kleineren Subsystem mit $i - 1$ Kraftwerksblöcken nach Brückl (2006) [75] rekursiv formuliert werden als:

$$Pr_i(P_A > P) = Pr_{(i-1)}(P_A > P) * (1 - p_i(t)) + Pr_{(i-1)}(P_A > (P - P_i)) * p_i(t)$$

Das in Abbildung 19 dargestellte Flussdiagramm nach Nolting et al. (2020) fasst die notwendigen Schritte zur Berechnung der Verteilung der verfügbaren Kapazitäten zu einem Zeitpunkt t unter Berücksichtigung von insgesamt n Kraftwerksblöcken zusammen. Dieser Prozess muss für jede untersuchte Stunde durchgeführt werden, da die Wahrscheinlichkeit der Nichtverfügbarkeit für jede Stunde variiert. [34]



Verteilungsfunktion der gesicherten Einspeiseleistung zur Stunde t

Abbildung 19: Flussdiagramm zur Bestimmung der Verteilungsfunktion der gesicherten Einspeiseleistung aller hydrothermischen Kraftwerksblöcke im System

Die Komplexität der numerischen Simulationen führt jedoch zunächst trotz der Verwendung der effizienten Formulierung des Faltungsalgorithmus, wie sie von Ibanez und Milligan [76] veröffentlicht wurde, zu hohen Laufzeiten. Dies ist insbesondere auf die stündliche Auflösung zurückzuführen, die zu 8.760 Simulationsläufen pro untersuchtem Jahr führt. Aus diesem Grund wird das Rechencluster der RWTH Aachen für die Simulationsläufe genutzt. Durch den Einsatz von Hochleistungsrechnern und die Parallelisierung des Programmcodes kann die Laufzeit pro untersuchtem Szenariojahr von zunächst 6 Tagen auf durchschnittlich 4,5 Stunden reduziert werden.

Das Verfahren liefert schließlich eine Verteilung der verfügbaren Kapazität in Form einer Kurve, welche den verfügbaren Kapazitäten Wahrscheinlichkeitswerte zuordnet. Für ein größeres System mit $n \approx 600$ Kraftwerksblöcken ergibt sich die Verteilungsfunktion der gesicherten Einspeiseleistung wie in Abbildung 20 dargestellt. Dabei indizierend die gestrichelten Linien die Schwankungsbreite über ein simuliertes Jahr aufgrund der sich stündlich ändernden Ausfallwahrscheinlichkeiten der einzelnen Kraftwerksblöcke. [34]




Abbildung 20: Beispielhafte Verteilungsfunktion der gesicherten Einspeiseleistung hydrothermischer Kraftwerksblöcke für ein System mit $n \approx 600$ Kraftwerksblöcken

Berechnung der Residuallast

Neben der (Nicht-)Verfügbarkeit von steuerbaren Kraftwerksblöcken muss auch die Einspeisung fluktuierender erneuerbarer Energien sowie die elektrische Last modellseitig abgebildet werden. Im Rahmen des Simulationsmodells wird daher die Residuallast als Differenz zwischen der elektrischen Last und der Einspeisung aus erneuerbaren Kraftwerken berechnet. Diese Berechnungen erfolgen in stündlicher Auflösung für jedes der betrachteten Wetterjahre. Aus dem Schnittpunkt zwischen Leistungsbedarf (d.h. der Residuallast) und der Verteilungsfunktion der gesicherten Einspeiseleistung der verfügbaren Kraftwerksblöcke kann dann für jede Stunde in jedem betrachteten Wetterjahr die Lastdeckungswahrscheinlichkeit als Ausgangspunkt zur Bestimmung der wissenschaftlichen Kennzahlen der Versorgungssicherheit berechnet werden. [34]

Da diese Berechnungen nicht zum Kern des probabilistischen Simulationsmodells gehören, sondern notwendigen Modellinput liefern, dient dieser Abschnitt als kurze Zusammenfassung der angewandten Datenvorverarbeitungsmethoden (siehe Kapitel 2).

Um die Residuallast zu berechnen, müssen zwei Faktoren bestimmt werden: (1) die elektrische Last und (2) die Einspeisung der fluktuierenden erneuerbaren Energien, wie Photovoltaik, Offshore- und Onshore-Windenergie sowie Laufwasserkraft.

Für die Berechnung der elektrischen Last ist eine große Anzahl von Einflussgrößen zu berücksichtigen: Die relevanten Faktoren reichen von sozioökonomischen Einflüssen (z. B. Wochenarbeitszeit, Feiertage), über meteorologische Bedingungen (Temperatur, Bewölkung), bis hin zu technologischen Faktoren (Verbreitung von Sektorenkopplungstechnologien sowie Effizienzstandards etc.). Kurzfristig prägen vor allem kalendarische Effekte, d. h. täglich, wöchentlich und saisonal wiederkehrende Verbrauchsmuster, den Lastgang. Neben diesen Kalendereffekten haben vor allem die Außentemperaturen einen Einfluss auf die elektrische Last.

Um die Temperaturabhängigkeit der Lasten in den untersuchten Ländern zu simulieren, werden in Anlehnung an den Ansatz von ENTSO-E (2018) [8] länderspezifische Funktionen ab-

geleitet. Analog zum in Behm, Nolting und Praktiknjo (2020) [77] beschriebenen Ansatz werden zu diesem Zweck kubische Regressionsgleichungen aufgestellt, mittels derer Standardlastprofile von Typtagen anhand der jeweiligen Tagesmitteltemperatur skaliert werden. Diese Regressionsfunktionen spiegeln somit den Zusammenhang zwischen elektrischer Last und der Außentemperatur in einem Land wider. Die Temperatursensitivität der Lasten werden mit diesen Funktionen, Temperaturdaten von 30 Wetterjahren und den normierten Lastprofilen des Mid-term Adequacy Forecast (MAF) Berichts von ENTSO-E (2016) [78] simuliert. Dieser Ansatz führt zu jährlichen Lastkurven in stündlicher Auflösung, welche die meteorologischen Einflüsse jedes der 30 untersuchten Wetterjahre im Zeitraum von 1986 bis 2015 widerspiegeln [39]. Eine Analyse der entstehenden Spitzen Lasten in Deutschland ist in Abbildung 21 überblicksartig dargestellt.




Abbildung 21: Spitzenlast in Deutschland im Untersuchungszeitraum von 1986 bis 2015

Ein alternativer Ansatz zur Erzeugung von elektrischen Lastprofilen für unterschiedliche Wetterjahre basierend auf künstlichen neuronalen Netzen wird von Behm, Nolting und Praktiknjo (2020) [77] entwickelt. Beiden Methoden ist gemeinsam, dass zwar die meteorologischen Einflüsse auf die elektrische Last abgebildet werden können, diese allerdings basierend auf historischen Daten bestimmt werden [39].

Zur Modellierung der fluktuierenden erneuerbaren Energieerzeugung werden zwei an der Gemeinsamen Forschungsstelle der Europäischen Kommission entwickelte Datensätze verwendet (González Aparicio et al., 2017, 2016) [79,80]. Die hier verwendeten Datensätze umfassen standardisierte, stündliche Einspeiseganglinien für Wind (offshore und onshore) und Photovoltaik für 30 Wetterjahre (1986–2015). Zusätzlich werden die vom Erdbeobachtungsprogramm Copernicus der Europäischen Union veröffentlichten Daten zur täglichen Einspeisung von Laufwasserkraftwerken genutzt und für die verwendete stündliche Auflösung interpoliert (Copernicus, 2018) [81]. Basierend auf diesen normierten Zeitreihen und den angenommenen installierten Leistungen der erneuerbaren Energien für die untersuchten Jahre können die Einspeiseganglinien für alle Wetterjahre abgeleitet werden.

Schließlich kann die Residuallast als Differenz zwischen der elektrischen Last und der erneuerbaren Einspeisung berechnet werden. Der Schnittpunkt der Verteilungskurve der verfügbaren Kapazitäten und der Residuallast (siehe Abbildung 22) bestimmt die Wahrscheinlichkeit,

dass die elektrische Last in einer spezifischen Stunde in einem bestimmten Wetterjahr gedeckt werden kann. In der vorliegenden Abbildung beträgt die Wahrscheinlichkeit 90 %, dass die Residuallast in der vorliegenden Stunde gedeckt werden kann [34].




Abbildung 22: Beispielhafte Berechnung der Wahrscheinlichkeit zur Deckung der Residuallast

Beiträge von benachbarten Ländern

Um eine umfassende Modellierung zu ermöglichen, müssen internationale Lastflüsse und die daraus resultierenden Importkapazitäten zur Deckung der elektrischen Last in Deutschland sowie die Exporte aus Deutschland berücksichtigt werden. In einem ersten Modellierungsansatz werden Beiträge aus folgenden Ländern berücksichtigt: Österreich (AT), Belgien (BE), Schweiz (CH), Tschechische Republik (CZ), Dänemark (DK), Frankreich (FR), Niederlande (NL), Norwegen (NO), Polen (PO) und Schweden (SE), da diese Länder derzeit direkt an das deutsche Stromnetz angeschlossen sind. Die auf stündlichen Kapazitätsbilanzen für alle Nachbarländer beruhende Vorgehensweise zur Berücksichtigung bilateraler Beiträge aus dem benachbarten Ausland lässt sich wie folgt zusammenfassen:

- 1) Berechnen der Kapazitäten der steuerbaren Kraftwerke in jedem Nachbarland und jedem Untersuchungsjahr in stündlicher Auflösung.
- 2) Ermitteln der temperaturabhängigen Last- und Einspeiseganglinien je Wetterjahr in stündlicher Auflösung, um die Residuallastkurven für jedes Nachbarland zu berechnen.
- 3) Bestimmen der möglichen Beiträge jedes Nachbarlandes als Differenz zwischen verfügbaren Kapazitäten und Residuallast. Für einige Länder kann dieser Beitrag während den Zeiten der deutschen Spitzenlast negativ sein, die entspricht einer Berücksichtigung von Exporten aus Deutschland zur Deckung der elektrischen Last im jeweiligen Nachbarland.
- 4) In einem letzten Schritt begrenzen wir den bilateralen Lastfluss anhand der verfügbaren Netto-Übertragungskapazitäten (NTCs) anhand der Net Transfer Capacities (NTCs), welche durch die entso-e veröffentlicht werden [78].

Diese potenziellen Beiträge der Nachbarländer werden lastseitig im probabilistischen Simulationsmodell berücksichtigt. Mögliche Importe werden von der Residuallast in Deutschland subtrahiert, wie in Abbildung 23 dargestellt [34].




Abbildung 23: Berücksichtigung des Importpotentials durch die Nachbarländer Deutschlands im probabilistischen Simulationsmodell

Berechnung der Kennzahlen der Versorgungssicherheit

Um realistische Bedingungen abbilden zu können, müssen wir probabilistische Einflüsse im Modell berücksichtigen. Auf der Lastseite beinhaltet dies meteorologische Einflüsse auf die Nachfrage nach Elektrizität und Importpotentiale. Auf der Angebotsseite müssen sowohl Wiedereinflüsse auf die erneuerbare Einspeisung als auch stündlich Veränderungen der Wahrscheinlichkeiten für Kraftwerksverfügbarkeiten berücksichtigt werden. Dies führt zu stündlichen Verschiebungswahrscheinlichkeiten zur Deckung der Residuallast wie in Abbildung 23 dargestellt. Stochastische Kennzahlen spiegeln dieses schwankende Verhalten wider [34].

Basierend auf den Modellergebnissen lässt sich die stündliche *Loss of Load Probability (LoLP)* bestimmt. Diese gibt an, mit welcher Wahrscheinlichkeit die zur Verfügung stehende Einspeiseleistung in einer betrachteten Stunde t nicht ausreicht, um den gesamten Bedarf zu decken. Somit handelt es sich nicht um die Wahrscheinlichkeit eines Blackouts, sondern vielmehr um die Lastüberhangwahrscheinlichkeit, d.h. die Wahrscheinlichkeit, mit der einzelne Verbraucher, über die bei der Berechnung berücksichtigten Nachfrageflexibilitäten hinaus, Lasten reduzieren müssen (die Abschaltung einzelner Verbraucher stellt dabei die Ultima Ratio dar, vgl. Praktiknjo, 2016 [[34,82]]). Diese kann zu in einer Stunde t als Komplementär zur Lastdeckungswahrscheinlichkeit $Pr_{Lastdeckung}(t)$ über folgenden Zusammenhang bestimmt werden:

$$LoLP = 1 - Pr_{Lastdeckung}(t)$$

Die Aggregation der stündlichen Lastüberhangwahrscheinlichkeiten über ein Jahr wird als *Loss of Load Expectation (LoLE)* bezeichnet und in Stunden pro Jahr [h/a] angegeben. Bei der Berechnung einer mittleren Lastunterdeckungsdauer werden häufig unterschiedliche Witterungsverhältnisse in Form einer Menge an Wetterjahren berücksichtigt. Ein Wetterjahr stellt

dabei einen geschlossenen Datensatz dar, welcher die Korrelationen zwischen der Einspeisung der erneuerbaren Energieträger (Windenergie, Photovoltaik und Laufwasser), der elektrischen Last und den meteorologischen Bedingungen abbildet. Hinsichtlich der Eintrittswahrscheinlichkeiten der einzelnen Wetterjahre wird dabei zumeist eine Gleichverteilungsannahme getroffen [39]. Für ein spezifisches Wetterjahr ergibt sich die Kennzahl $LoLE$ demnach als

$$LoLE = \sum_{t=1}^{t=8760} LoLP_1 * 1h$$

Eine weitere Kenngröße ist die *Expected Energy not Served (EENS)* in Gigawattstunden pro Jahr [GWh/a]. Diese Kennzahl wird auch als *Expected Unserved Energy (EUE)* bezeichnet, vgl. Wentlent et al. (2020) [83]. Hierbei handelt es sich um den über die einzelnen Stunden aggregierten Erwartungswert der nicht gedeckten Nachfrage nach elektrischer Energie.




Abbildung 24: Bestimmung der Expected Energy not Served (EENS) während einer Stunde t in einem Beispielsystem

Wie in Abbildung 24 dargestellt, ergibt sich die während einer Stunde zu erwartende Lastunterdeckungsmenge $A_{EENS,t}$ als Fläche zwischen einer Parallelen zur X-Achse bei vollkommener Lastdeckungswahrscheinlichkeit, der Verfügbarkeitsverteilung der Einspeiseleistung konventioneller Erzeugungseinheiten sowie der Residuallast. Die Residuallast berechnet sich wiederum als Differenz zwischen elektrischer Last und der Einspeiseleistung erneuerbarer Energieerzeugungsanlagen während der betrachteten Stunde t .

$$EENS = \sum_{t=1}^{t=8760} A_{EENS,t} * 1h$$

Die eingeführten Kennzahlen der Versorgungssicherheit können für alle 30 Wetterjahre ermittelt werden. Dies ermöglicht die statistische Auswertung von Wittereinflüssen auf die Versorgungssicherheit mit Elektrizität [34].

3.2 Auswahl relevanter Szenarien

Im folgenden Abschnitt werden die Kraftwerksdaten und die (unter anderem) untersuchten Szenarien vorgestellt. Um wissenschaftlich verlässliche Ergebnisse zu erzielen, ist es von großer Bedeutung, die qualitativ hochwertigsten verfügbaren Daten zu verwenden. Daher verwenden wir für unsere Modellierung nur öffentlich zugängliche Datensätze von etablierten Institutionen, von denen erwartet werden kann, dass sie frei von Verzerrungen und Voreingenommenheit sind.

Folgende Daten gehören zu den notwendigen Inputs:

- 1) Installierte steuerbare und erneuerbare Kraftwerkskapazitäten auf nationaler Ebene
- 2) Installierte Leistung von steuerbaren und erneuerbaren Anlagen in benachbarten Ländern
- 3) Internationale Netto-Übertragungskapazitäten (NTCs)
- 4) Weitere Details wie Systemstabilitätsmaßnahmen, abschaltbare Lasten und Netzstabilitätseinheiten

Für die aktuell installierten Kapazitäten der steuerbaren Kraftwerke werden die nach Kraftwerksblöcken aufgeschlüsselte Liste der deutschen Kraftwerke verwendet, welche von der Bundesnetzagentur veröffentlicht wurde [84]. Zukünftige Inbetriebnahmen und Außerbetriebnahmen werden gemäß [85] implementiert. Zusätzlich wird ein Ausbaupfad von kleineren KWK-Anlagen gemäß BNetzA berücksichtigt [86]. Für die erneuerbaren Energien in Deutschland werden die Daten aus dem MAF-Bericht von 2018 verwendet [35]. Dabei werden die Daten für die Jahre 2020 und 2025 linear interpoliert, um die Bedingungen in den untersuchten Szenariojahren widerzuspiegeln. Die resultierenden Kapazitäten sind in Abbildung 25 für drei Szenariojahre 2020, 2022 und 2023 dargestellt. [34]




Abbildung 25: Installierte Kapazitäten nach Kraftwerkstechnologie in Deutschland in den Jahren 2020, 2022 und 2023

Um Datenkonsistenz zu gewährleisten, wird für die installierte Leistung der erneuerbaren Energien in den Nachbarländern dieselbe Datenquelle verwendet [35]. Für die installierte Leistung von steuerbaren Kraftwerken verwenden wir den Datensatz des MAF 2017 [8] auf

Basis der wesentlichen Änderungen gemäß den neuen MAF 2018 Daten [35]. Der beschriebene Ansatz resultiert letztendlich in den installierten Kapazitäten für die mitteleuropäischen Länder für jedes untersuchte Szenariojahr (siehe Abbildung 26).




Abbildung 26: Installierte Kapazitäten der deutschen Nachbarländer für die Jahre 2020, 2022 und 2023

Die notwendigen NTC-Werte zur Abschätzung des Importpotenzials werden aus entso-e [78] entnommen und auf Basis von entso-e [35] aktualisiert. Anschließend werden die Daten für die untersuchten Szenariojahre interpoliert. Zusätzlich zu den dargestellten installierten Kapazitäten werden Maßnahmen zur Systemzuverlässigkeit hinzugefügt. In Anlehnung an den Ansatz von entso-e [8], werden diese Maßnahmen zur elektrischen Last addiert, da sie die zusätzliche Nachfrage widerspiegeln, wie ebenfalls von [35] vorgeschlagen. Im Gegensatz zu Maßnahmen der Systemzuverlässigkeit, die die Last tendenziell erhöhen, können flexible Lasten und abschaltbare Lasten die Spitzenlast reduzieren. Daher wird ebenfalls eine Reduzierung von 1,2 GW auf der Lastseite berücksichtigt. Schließlich spiegelt sich der von der Bundesnetzagentur [32] berichtete Anstieg der Netzreserven durch einen Rückgang der Spitzenlast um 1,14 GW wider. [34]

Nachdem die notwendigen Eingangsdaten beschrieben wurden, wird nachfolgend auf die untersuchten Szenarien eingegangen. Unter anderem werden die Jahre 2020, 2022, und 2023 als Szenariojahre gewählt. Diese Wahl basiert auf der Tatsache, dass diese Jahre den politisch beschlossenen Ausstieg aus der Kernenergienutzung mit 8 GW Kernkraftwerksleistung in Deutschland im Jahr 2020, 4 GW installierter Leistung im Jahr 2022 und 0 GW installierter Leistung im Jahr 2023 beleuchtet. Da zwischen den Jahren 2020 und 2021 keine Änderungen zu erwarten waren, werden diese in der Simulation nicht weiter berücksichtigt. Außerdem spiegeln die Szenarien mit zusätzlichen Kapazitätsreduzierungen von 5 GW bzw. 8 GW mögliche Resultate der laufenden Diskussion über einen geplanten Ausstieg aus der Kohleverstromung wider und werden daher als relevant für die Analyse der energiepolitischen Ziele eingestuft. Dieser Ansatz führt zu 9 Szenarien, die in Tabelle 7 zusammengefasst sind.

Tabelle 7: Zusammenfassung der untersuchten Szenarien

Year	Additional phase-out of coal-fired power plants		
	0 GW	5 GW	8 GW
<i>2020</i>	2020	2020_-5GW	2020_-8GW
<i>2022</i>	2022	2022_-5GW	2022_-8GW
<i>2023</i>	2023	2023_-5GW	2023_-8GW

Um Kraftwerksparks zu generieren, welche Szenarien mit zusätzlichem Kohleausstieg reflektieren können, werden die ältesten Steinkohle- und Braunkohlekraftwerke aus der Liste der installierten Kapazitäten bis zum Erreichen des Schwellwertes ausgeschlossen. Für die 5-GW-Reduktionsszenarien entspricht dies der Entfernung von 27 Kraftwerksblöcken mit Inbetriebnahmedaten zwischen 1923 und 1972 aus dem Kraftwerkspark für die probabilistische Simulation. Für die 8-GW-Reduktionsszenarien werden 33 Blöcke mit Inbetriebnahmedaten zwischen 1923 und 1975 aus dem Energiesystem für die Simulation ausgeschlossen.

Die Modellergebnisse der vorgestellten Szenarien unter Anwendung des vorgestellten Simulationsmodells und der notwendigen Eingangsdaten können unter [34] eingesehen werden.

4 Metamodellierung komplexer Energiesystemmodelle

Im Gegensatz zu früheren Ansätzen [87], in denen lediglich über eine zweistufige Metamodellierung die rechenintensive Teilberechnung der stündlich aufgelösten Wahrscheinlichkeitsverteilungen mit reduzierter Dimensionalität (d.h. lediglich konventionelle Kraftwerkskapazitäten) approximiert wurden, wird nachfolgend ein methodischer Ansatz vorgestellt, welcher die Zielgrößen (LOLP / EENS) des probabilistischen Simulationsmodells zur Bewertung der Versorgungssicherheit mit Elektrizität unter Berücksichtigung aller relevanten Eingangsgrößen (16 Dimensional) direkt prognostizieren kann.

Zunächst wird eine Vorauswahl potenzieller Regressionsmethoden aus dem ML-Bereich mit Hilfe einer Voranalyse zur späteren Anwendung am probabilistischen Simulationsmodell getroffen. Diese Voranalyse berücksichtigt Ergebnisse eines durchgeführten Methodenvergleichs anhand von mathematischen Testfunktionen sowie Ergebnisse der Literaturrecherche zum Stand der Technik. Im Anschluss wird die genaue Problemstellung des Metamodellierungsproblems definiert und Szenarien vorgestellt, welche als unabhängige Testdaten zur Bewertung der Prognosegüte der Metamodelle herangezogen werden. Im nächsten Schritt wird die spezifisch auf die Problemstellung angepasste Methode zur Generierung der Trainingsdaten näher vorgestellt, welche ebenfalls detailliert in der Veröffentlichung *Uplifting the Complexity of Analysis for Probabilistic Security of Electricity Supply Assessments using Artificial Neural Networks* [46] beschrieben wurde. Diese Veröffentlichung befindet sich zum Zeitpunkt der Erstellung dieses Abschlussberichtes noch im Review Process beim Elsevier Journal *Energy and AI*. Ein Preprint ist allerdings bereits zum Zeitpunkt der Erstellung dieses Abschlussberichtes im SSRN des Elsevier Verlags verfügbar. Im Anschluss erfolgt die Bewertung der Metamodelle anhand unabhängiger Testdaten und ein Vergleich der unterschiedlichen Regressionsmethoden. Die Ergebnisse des Methodenvergleiches werden im Nachgang zu dem Abschlussbericht in der Konferenzveröffentlichung *Accelerating the generation of results in the simulative security of electricity supply assessments with machine learning: A comparison of methods* (SWEDES 2024) vorgestellt.

4.1 Voranalyse

Die Bewertung von Methoden zur Metamodellierung, welche auf Basis der Literaturrecherche ausgewählt wurden, erfolgt zunächst anhand von Testfunktionen. Ursächlich hierfür ist, dass im frühen Projektstadium eine direkte Anwendung am Simulationsmodell zur Versorgungssicherheitsbewertung mit Elektrizität nicht möglich war. Darüber hinaus ist eine umfangreiche Analyse einer Vielzahl an Metamodellierungsmethoden anhand von zeitintensiven simulationsbasierten Ergebnissen nur schwer realisierbar. Ferner können die programmierten Codes im Vorfeld auf Funktionalität hin überprüft werden. Insgesamt umfasst die Voranalyse zehn Modellierungsmethoden, zwei Versuchsplankombinationen sowie 25 Problemstellungen (fünf Testfunktionen in jeweils fünf verschiedenen Dimensionen), sodass insgesamt 500 optimierte Metamodellierungsergebnisse in die Auswertung einfließen.

Ausgewählt wurden Testfunktionen mit unterschiedlichen signifikanten physikalischen Eigenschaften bzw. Formen (*Many Local Minima*, *Bowl-/ Plate-/ Valley-Shaped*, *Steep Ridges/Drops*) sowie Dimensionen (Anzahl Einflussgrößen/ Features). Ziel hierbei ist es, eine möglichst große Bandbreite von Problemstellungen abzudecken, da eine exakte Abbildung

der späteren Problemstellung im Vorhinein nicht möglich ist. Eine Übersicht über die verwendeten Testfunktionen, die jeweilige Anzahl an getesteten Einflussgrößen und die Wertebereiche, in denen sie variiert wurden, kann aus Tabelle 8 entnommen werden.

Tabelle 8: Übersicht der verwendeten Testfunktionen

Testfunktion	Formel	Dimension	Variation
Sphere	$f(x) = \sum_{i=1}^n x_i^2$	2-6	$x_i \sim U(-2.5, 2.5)$
Zakharov	$f(x) = \sum_{i=1}^n x_i^2 + \left(\sum_{i=1}^n 0.5i \cdot x_i \right)^2 + \left(\sum_{i=1}^n 0.5i \cdot x_i \right)^4$	2-6	$x_i \sim U(-2.5, 2.5)$
Styblinski-Tang	$f(x) = \frac{1}{2} \sum_{i=1}^n (x_i^4 - 16x_i^2 + 5x_i)$	2-6	$x_i \sim U(-2.5, 2.5)$
Rosenbrock	$f(x) = \sum_{i=1}^{n-1} [10(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	2-6	$x_i \sim U(-2.5, 2.5)$
Rastrigin	$f(x) = 10n + \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i)]$	2-6	$x_i \sim U(-1, 1)$

Zur Minimierung der benötigten Einflussgrößen-Kombinationen und der zugehörigen Testfunktions-Ergebnisse, welche zur Metamodellierung der Testfunktionen benötigt werden, wird auf Methoden der statistischen Versuchsplanung bzw. des *Design of Experiment* (DoE) zurückgegriffen. Verwendung finden zwei unterschiedliche Versuchsplankombinationen. Die erste Versuchsplankombination beinhaltet einen vollfaktoriellen Versuchsplan (vfv) und einen zentral zusammengesetzten Versuchsplan (zzv). Die zweite Versuchsplankombination nutzt einen vollfaktoriellen Versuchsplan (vfv) und einen Latin Hypercube (lhc). Abbildung 27 zeigt exemplarisch die beiden verwendeten Versuchsplankombinationen für den Fall mit drei Einflussfaktoren (n=3).




Abbildung 27: Versuchsplankombinationen links vfv+zzv und rechts vfv+lhc

Auf Grundlage der Literaturrecherche werden folgende Metamodellierungsmethoden aus dem Bereich des Maschinellen Lernens in der Analyse betrachtet: *Support Vector Regression*

(SVR), *MultiVariate Adaptive Regression Spline* (MARS), *K-Nearest Neighbor* (KNN), *CART Regression Trees* (CART), *Random Forest* (RF), *Gaussian Processes Regression* (GPR), *Feed-Forward Neural Network* (MLP) und *Recurrent Neural Networks* (VRNN, LSTM, GRU). In Abbildung 28 werden die Ergebnisse der Voranalyse als Mittelwert über alle Testfunktionen, Dimensionen und Versuchsplankombinationen aufgeschlüsselt nach den einzelnen Metamodellierungsmethoden dargestellt. Als Bewertungsgrundlage der Prognosegüte wird hierbei das Bestimmtheitsmaß (R^2) herangezogen, ermittelt an 1.000 vom Training unabhängigen Testdaten.




Abbildung 28: Mittleres Bestimmtheitsmaß über alle Testfunktionen, Dimensionen & Versuchsplankombinationen

Wie in Abbildung 28 ersichtlich, erzielt die statistische GPR-Methode im Mittel über alle untersuchten Problemstellungen die höchste Prognosegüte. Auf den Rängen 2 bis 4 folgen Methoden aus dem Bereich des *Deep Learning*. Zunächst die Recurrent Neural Networks GRU und LSTM, gefolgt vom FFNN (MLP). Die übrigen statistischen Methoden SVR, MARS und KNN belegen die Ränge im Mittelfeld (Rang 5-7), während die Methoden aus dem Bereich der Entscheidungsbäume (RF & CART) und die Ursprungsmethode der Recurrent Neural Networks (VRNN) die hinteren Plätze einnehmen.

Abbildung 28 zeigt auch schon, dass die Prognosegüte nicht nur von der gewählten Methodik, sondern auch von der konkreten Problemstellung abhängig ist. Ersichtlich ist dies beispielsweise beim direkten Vergleich zwischen GPR und GRU. Während die GPR (R^2 rd. 0,84) eine höhere Prognosegüte über alle Problemstellungen als GRU erreicht (R^2 rd. 0,80), erzielen beide Methoden im Mittel ohne die Testfunktion *Rastrigin* eine äquivalente Prognosegüte von rd. 0,93 beim Bestimmtheitsmaß (R^2).

Neben der vorliegenden Problemstellung und der gewählten Methodik hat ebenfalls der verwendete Versuchsplan einen entscheidenden Einfluss auf die Prognosegüte. In Abbildung

29 wird der Mittelwert des Bestimmtheitsmaßes über alle Problemstellungen aufgeschlüsselt nach den einzelnen Methoden und Versuchsplankombinationen dargestellt.




Abbildung 29: Mittleres Bestimmtheitsmaß aufgeschlüsselt nach Versuchsplankombinationen

Die Abhängigkeit zwischen gewähltem Versuchsplan und der Prognosegüte ist beispielsweise gut anhand der *RNN* (VRNN, LSTM & GRU) ersichtlich. Diese weisen in Kombination mit vFV+lhc im Mittel über alle Problemstellungen hinweg eine höhere Prognosegüte auf als in Kombination mit vFV+zzV. Bei den statistischen Methoden GPR und SVR hingegen ist es genau umgekehrt.

Die Voranalyse zu Metamodellierungsmethoden hat aufgezeigt, dass Metamodellierungen immer problemspezifisch realisiert werden müssen. Das bedeutet, dass in Abhängigkeit zur konkreten Problemstellung sowohl Methode als auch Versuchsplan passend ausgewählt werden müssen, um eine möglichst hohe Prognosegüte zu erzielen. Dennoch kann aufgrund der großen Bandbreite an Problemstellungen, welche mit der Voranalyse abdeckt wird, eine valide Vorauswahl an sinnvollen Methoden für die Anwendung am probabilistischen Modell zur Bewertung der Versorgungssicherheit mit Elektrizität getroffen werden. Aus dem Bereich der statistischen Methoden wird die GPR und aus dem Bereich des *Deep Learnings* MLP, LSTM und GRU ausgewählt. Die Mehrfachauswahl von *Deep Learning* Methoden ist sinnvoll, da diese Methoden signifikante Unterschiede bezüglich der Trainingszeit und der Hardwareanforderungen aufweisen. Insbesondere die *Recurrent Neural Networks* Methoden weisen eine erhöhte Trainingszeit und einen erhöhten Arbeitsspeicherbedarf auf.

Diese Ergebnisse werden auch durch die Literaturrecherche bestätigt. In Abbildung 30 ist ersichtlich, mit welcher Häufigkeit Methoden des Maschinellen Lernens in wissenschaftlichen Veröffentlichungen zum Thema Metamodellierung in energiebezogenen Fachzeitschriften in der Scopus-Datenbank in den Jahren 2010 bis 2022 verwendet wurden. Insbesondere FFNN (MLP) und GPR wurden in den vergangenen zehn Jahren am häufigsten verwendet. RNN

Methoden wurden in diesem Zeitraum kaum verwendet, allerdings verzeichnen diese in den letzten vier Jahren den größten Anstieg von allen betrachteten Methoden. Die Ensemble Methoden haben insbesondere in den Jahren 2021/2022 einen großen Anstieg verzeichnet. Dieser Anstieg war erst in einer späteren Revision der Veröffentlichung ersichtlich, sodass zusätzlich als Ensemble Methode XGBoost beim Methodenvergleich betrachtet wird.




Abbildung 30: Wissenschaftliche Veröffentlichungen zum Thema Metamodellierung in energiebezogenen Fachzeitschriften in der Scopus-Datenbank von 2010 bis 2022 [43]

4.2 Problemstellung und Testszenarien

Für die Metamodellierung des probabilistischen Simulationsmodells zur Bewertung der Versorgungssicherheit mit Elektrizität Deutschlands wurden unterschiedliche Regressionsproblemstellungen betrachtet. Die nachfolgenden Ergebnisse beziehen sich auf das Regressionsproblem für die Winter-Analyse 2022/2023 unter Betrachtung der Laufzeitverlängerung für deutsche Kernkraftwerke. Dieses Regressionsproblem weist mit 16 Dimensionen (Einflussgrößen) die höchste Komplexität auf. Hierbei werden als Einflussgrößen die Kapazitäten der erneuerbaren Erzeuger (Photovoltaik, Onshore-/Offshore-Windkraft, Wasserkraft), die Kapazitäten und Ausfallwahrscheinlichkeiten der konventionellen Kraftwerke (Braun-/Steinkohle-, Gas-, Öl- und Kernkraftwerke), das Importpotenzial der Nachbarländer und die anliegende Stromlast berücksichtigt. Prognostiziert werden die beiden Kenngrößen (Zielgrößen) EENS und LOLP. Die Grenzen des Versuchsraumes bzw. die Grenzen, in denen die späteren Metamodelle Gültigkeit besitzen sollen, werden in Tabelle 9 dargestellt.

Tabelle 9: Grenzen des Versuchsraumes [46]

Boundaries	Hard coal	Natural Gas	Lignite	Oil	Nuclear energy	Other
Min.	0.0	0.0	0.0	0.8	0.0	2.0
Max.	25.0	45.0	20.0	1.5	5.0	4.0
Boundaries	Wind Onshore	Wind Offshore	Photovoltaic	Water	Load	Import potential
Min.	0.0	0.0	0.0	1.0	30.0	0.0
Max.	100.0	15.0	100.0	5.0	100.0	50.0
Boundaries	Planned Non Availabilities					
	Hard coal	natural gas	Lignite	Nuclear energy		
Min.	0.0414	0.0109	0.0352	0.0855		
Max.	0.1837	0.1597	0.1241	0.1742		

Zur Bewertung der Prognosegüte der erstellten Metamodelle werden unterschiedliche Szenarien des deutschen Kraftwerksparks betrachtet. Diese hypothetischen Kraftwerksparkszenarien werden ausgehend vom Kraftwerkspark Deutschlands zum Stand 2022 erstellt, indem Kraftwerkskapazitäten variiert werden. Die verwendeten Szenarien sind:

0. Unsicherheitsszenario: Besteht aus einem künstlich zusammengesetzten Kraftwerkspark mit schweren Versorgungsengpässen, um die Leistungsfähigkeit der Metamodelle über den gesamten Wertebereich der Zielgrößen zu testen.
1. Basisfall: Tatsächlicher Kraftwerkspark ab November 2022 (BNetzA, 2022)
2. Ausstieg aus der Kernenergie: Abschaltung aller verbliebenen Kernkraftwerke in Deutschland ab April 2023
3. Kernenergieausstieg und zusätzlich fehlende Reservekapazitäten: Zusätzlich zu Fall (3) stehen keine Reservekapazitäten mehr zur Verfügung, welche nicht am Markt teilnehmen, aber im Falle eines Versorgungsengpasses aktiviert werden können.

Nachfolgend werden die zugrunde liegenden Daten näher beschrieben. Die Kraftwerkskapazitäten der Szenarien sind in Abbildung 31 dargestellt. Im Vergleich zum Basisszenario (Szenario (1)) sind die gesamten konventionellen Kraftwerkskapazitäten in den anderen Szenarien um ~4 GW für Szenario (2) und ~12 GW für Szenario (3) geringer. Dies betrifft sowohl die Kernkraftwerkskapazitäten als auch die Braunkohle-, Steinkohle- und Erdgaskapazitäten. Die installierten Kapazitäten der erneuerbaren Energieanlagen sind in allen Szenarien konstant.




Abbildung 31: Installierte konventionelle Kapazitäten in Deutschland nach Szenarien

[46]

Für die probabilistische Bewertung der Stromversorgungssicherheit werden stündliche Zeitreihendaten für 30 Wetterjahre verwendet. Dies umfasst wetterabhängige Unsicherheiten, die die Stromlast, die Stromerzeugung aus erneuerbaren Energien und die Importpotenziale für Strom aus den Nachbarländern beeinflussen. Die Verteilungen der Werte sind in Abbildung 32 dargestellt.




Abbildung 32: Boxplots der verwendeten wetterabhängigen Eingangsdaten (8760 Stundenwerte für jeweils 30 Wetterjahre) [46]

4.3 Methode zur Generierung der Trainingsdaten

Nachfolgend wird die statistische Methodik zur Generierung der über das probabilistische Modell zu simulierenden Faktorkombinationen (Trainingsdaten) näher erläutert. Das Ziel hierbei ist, den Versuchsraum möglichst effektiv abzutasten, sodass die benötigte Zeit zur Simulation der Trainingsdaten reduziert wird.


4.3.1 Statische Methodik zur Abtastung des Versuchsraumes

Eine Besonderheit des vorliegenden Metamodellierungsproblems sind die Zielgrößen, da diesen Grenzen gesetzt sind. Zum Beispiel kann der LOLP-Wert nur Werte zwischen Null und Eins annehmen. In Bereichen des Versuchsraumes, in denen beispielsweise eine signifikante Lastüberdeckung vorliegt, nimmt der LOLP-Wert nur den Wert Null an.

Die Grenzen der Zielgrößen führen dazu, dass in Großflächigen Bereichen des 16-dimensionalen Versuchsraums die Zielgrößen keine Änderung erfahren. Hieraus ergibt sich ein Problem bei der Erzeugung von Trainingsdaten z.B. für ein künstliches neuronales Netz. Wird zur Generierung des Trainingsdatensatzes eine bewährte Methode, z.B. ein LHD, verwendet, führt dies dazu, dass der generierte Trainingsdatensatz eine Vielzahl an Faktorkombinationen aus stagnierenden Bereichen aufweist, welche einen Großteil des Versuchsraumes einnehmen. Dies hat zur Folge, dass der Trainingsdatensatz beispielsweise eine hohe Anzahl von Nullwerten für den LOLP-Wert enthält (rd. 92,0 %). Dies erschwert die Generalisierung des Metamodells und verschlechtert die Prognosegüte. Je besser die Versorgungssicherheit eines Landes ist, desto mehr Raum nehmen diese Bereiche im Versuchsraum ein. Aufgrund

des Vorstehenden muss bei der vorliegenden Problemstellung eine anwendungsspezifische Anpassung der bewährten Methoden erfolgen.

Zur Gewährleistung einer hohen Prognosegüte bei gleichzeitig möglichst wenigen zu simulierenden Faktorkombinationen wird eine sogenannte *filtered random distribution* (FRD) angewendet. Hierbei wird der Versuchsraum anhand eines Kriterium gefiltert, sodass der Versuchsraum nur in einem bestimmten Bereich abgetastet wird. Abbildung 33 verdeutlicht diese Methodik schematisch für eine dreidimensionale Problemstellung.



**Abbildung 33: Links ungefilterte / rechts gefilterte Versuchspläne
(vollfaktorieller Versuchsplan rot und LHD blau) [46]**

Um Faktorkombinationen herauszufiltern, die keine Lastunterdeckung aufweisen, wird der Lastdeckungsgrad (LDG) als Bedingung verwendet. Dieser kann bereits auf Basis der Einflussgrößen des Simulationsmodells nach folgender Formel berechnet werden.

$$LDG = \frac{\sum(\text{Erzeugerkapazität} \cdot (1 - \text{Nichtverfügbarkeit})) + \text{Importpotenzial}}{\text{anliegende Stromlast}}$$

Um die relevanten Bereiche des Versuchsraumes möglichst effizient abzutasten, setzt sich der Versuchsplan aus zwei einzelnen Versuchsplänen zusammen. Zunächst wird ein gefilterter teilfaktorieller Versuchsplan erstellt, um die Eckpunkte des Versuchsraumes abzutasten. Auf die Verwendung eines vollfaktoriellen Versuchsplan wird aufgrund der hohen Anzahl an Faktorkombinationen (2^{16} vor Filterung) verzichtet. Die Grenzen des Versuchsraumes sind durch die Minima und Maxima der Einflussgrößen definiert und werden durch die zu prognostizierenden Szenarien vorgegeben. Für die Abtastung der relevanten Bereiche im Versuchsraum wird im zweiten Schritt ein FRD erstellt. Hierbei werden zunächst so viele zufällige gefilterte Faktorenkombinationen ermittelt, bis eine gewünschte Anzahl von Faktorenkombinationen mit Lastunterdeckung gefunden wurde. Anschließend wird die Verteilung im Versuchsraum des FRD mit Hilfe der *Pearson-Korrelation* bewertet. Dieser Faktor ist ein dimensionsloses Maß für die Kovarianz, welcher Werte zwischen -1 und 1 annehmen kann. Die Pearson-Korrelation ist im Gegensatz zur Kovarianz nicht von einer Messskala abhängig und daher universell vergleichbar. Nimmt dieser Faktor den Wert Null an, so besteht kein linearer Zusammenhang zwischen den Variablen. Nähert sich der Wert hingegen einem Extrempunkt (+/-1), so nimmt der negative bzw. positive lineare Zusammenhang zu. Die Optimierung des Versuchsplanes wird solange fortgeführt, bis 1000 mal kein besser bewerteter Versuchsplan gefunden wurde. Eine Verbesserung wird erzielt, wenn der Pearsons-Korrelationswert näher an Null liegt. Abbildung 34 zeigt das prinzipielle Vorgehen bei der Versuchsplanerstellung schematisch.




Abbildung 34: Schematische Darstellung der Versuchsplanerstellung FRD [46]

Bei der FRD-Filterung sinkt aus Gründen der Wahrscheinlichkeitsverteilung der prozentuale Anteil an Faktorkombinationen, je kleiner der Lastdeckungsgrad ist, siehe Abbildung 35. Durch die Zufallsgenerierung werden hierdurch mehr Faktorkombinationen mit höheren Lastdeckungsgraden gefunden. Dies kann durch die Lastfilterung allein nicht kompensiert werden. Aufgrund des vorstehenden wird zusätzlich eine erweiterte Filterung, die sogenannte *advance filtered random distribution* (AFRD), erprobt. Bei dieser Filterung wird der relevante Bereich des Lastdeckungsgrades in Zonen unterteilt und die Faktorkombinationen des Versuchsplanes gleichmäßig auf diese Zonen verteilt. Eine jeweils für die Filterungsart typische Verteilung der Faktorkombinationen eines Versuchsplanes über dem Lastdeckungsgrad wird im Histogramm in Abbildung 35 dargestellt.




Abbildung 35: Prozentualer Anteil der Faktorenkombinationen über dem Lastdeckungsgrad [46]

4.3.2 Reduktion der Trainingsdaten

Nachfolgend werden die beiden vorgestellten Filterungsarten (FRD/AFRD) miteinander verglichen und die mindestens benötigte Anzahl an Faktorkombinationen der Trainingsdaten eingegrenzt. Hierfür wurden Versuchspläne mit beiden Filterungsarten im Bereich von 2500 bis 6000 Faktorkombinationen erstellt. Das Training von künstlichen neuronalen Netzen sowie die Hyperparameteroptimierung unterliegen Zufallsschwankungen, sodass die Prognosegüte zwischen unterschiedlichen Hyperparameteroptimierungsdurchläufen schwanken kann. Aus diesem Grund wurde die Hyperparameteroptimierung für alle Versuchspläne mehrmals durchgeführt. Abbildung 36 stellt das Bestimmtheitsmaß an den Validierungsdaten exemplarisch für den LOLP Wert für jeweils zwanzig Hyperparameteroptimierungsdurchläufe pro Versuchsplan unter Verwendung eines MLP in einem Boxplot dar.




Abbildung 36: LOLP - Bestimmtheitsmaß an den Validierungsdaten für unterschiedliche Versuchspläne (MLP) [46]

Wie aus Abbildung 36 hervorgeht, steigt mit zunehmender Anzahl an Faktorkombinationen die Prognosegüte an den Validierungsdaten an. Darüber hinaus sinkt die Differenz zwischen Upper und Lower Whisker bzw. der Interquartilsabstand, sodass die Robustheit des Trainings und der Hyperparameteroptimierung mit steigender Anzahl an Faktorkombinationen zunimmt. Beim Vergleich der Filterungsarten wird deutlich, dass die AFRD Filterung insbesondere ab 4000 Faktorkombinationen eine höhere Prognosegüte und eine höhere Robustheit erzielt. Der AFRD Versuchsplan mit 6000 Faktorkombinationen erzielt durchgängig eine hohe Prognosegüte bzw. ein Bestimmtheitsmaß von über 0,9999, sodass dieser Versuchsplan im nachfolgenden für den Methodenvergleich verwendet wird.

4.4 Methodenvergleich an unabhängigen Testszenarien

Zur Bewertung der Prognosegüte beim Methodenvergleich werden die erstellten Metamodelle an unbekannten Datensätzen getestet. Hierfür werden vier Testszenarien mit jeweils 30 unterschiedlichen Wetterjahren ($1.051.200 \text{ Testpunkte} = 30 \text{ Wetterjahre} \cdot 8760 \text{ h/a} \cdot 4 \text{ Szenarien}$) herangezogen, welche in Kapitel 4.2 ausführlich beschrieben wurden. Abbildung 37 zeigt das Bestimmtheitsmaß über alle Testszenarien exemplarisch für den LOLP Wert aller zwanzig Hyperparameteroptimierungsdurchläufe der einzelnen *Deep Learning* Methoden mit dem Versuchsplan AFRD 6000 als Trainingsdatensatz.




Abbildung 37: LOLP - Bestimmtheitsmaß über alle unabhängigen Testszenarien für AFRD 6000 (MLP/VRNN/LSTM/GRU) [46]

Wie Abbildung 37 verdeutlicht, erzielen sämtliche *Deep Learning* Methoden an unabhängigen Testdaten in allen Hyperparameteroptimierungsdurchläufen hohe Prognosegüten ($R^2 > 0,9994$). Alle Methoden erreichen hierbei in einzelnen Hyperparameteroptimierungsdurchläufen ein hohes Bestimmtheitsmaß von 0,9999. Im Median liegen MLP und VRNN am nächsten an dieser Prognosegüte. Die Ergebnisse zeigen, dass bei der vorliegenden Problemstellung lediglich eine der Recurrent Neural Networks Methoden (VRNN) eine geringfügig höhere Prognosegüte erzielt als Feed-Forward-Natural-Networks (MLP). Recurrent Neural Networks weisen eine höhere Rechenintensität auf, sodass die Trainingszeit im Vergleich zu MLP bei VRNN um 13,3 %, bei LSTM um 72,3 % und bei GRU um 40,2 % erhöht ist. Aufgrund der geringeren Trainingszeit bei nur geringfügig geringerer Prognosegüte sind MLP gegenüber VRNN zu bevorzugen.

Während bei der Voranalyse klassische ML-Regressionsmethoden (GPR und XGBoost) noch mit *Deep Learning Methoden* vergleichbare Ergebnisse erzielen konnten, zeigt die direkte Anwendung am probabilistischen Simulationsmodell, dass diese bei dieser Anwendung nicht konkurrenzfähig sind. An den unabhängigen Testszenarien werden lediglich Bestimmtheitsmaße von 0,79 bis 0,96 erreicht. Ursächlich hierfür ist die hohe Dimensionalität des letztendlichen Regressionsproblems (16 dimensional). Dies führt zu einer hohen Anzahl an Trainings-samples, da die zu verarbeiteten Daten mit jeder Dimension exponentiell ansteigen. Im Gegensatz zu Deep Learning Methoden haben klassische ML-Regressionsmethoden bei einer hohen Anzahl an Trainingssamples Schwierigkeiten bei der Generalisierung des Regressionsproblems. Methoden zur Reduktion der Dimensionalität, wie z.B. Autoencoder, konnten die Prognosegüte nicht weiter steigern. Aufgrund des Vorstehenden wird auf eine detaillierte Darstellung der Ergebnisse verzichtet.

4.5 Bewertung der Metamodellierung

Wie bereits aus den vorigen Kapitel hervorgeht, weisen die simulierten und die über *Deep Learning Methoden* prognostizierten bzw. ermittelten Werte eine hohe Übereinstimmung auf. Die Schlussbewertung der Metamodellierung erfolgt nun anhand eines Metamodelles, welches mit einem MLP und einem AFRD 6000 Versuchsplan erstellt wurde. Wie dem vorstehenden Kapitel entnommen werden kann, erzielten MLP eine hohe Prognosegüte und weisen gleichzeitig die geringste Trainingsdauer im Methodenvergleich auf. Darüber hinaus erzielte der AFRD Versuchsplan mit 6000 Faktorkombinationen die höchste Robustheit aller untersuchten Versuchspläne. Abbildung 38 stellt die Prognosegüte an den vier unabhängigen Testszenarien (1.051.200 Testpunkten) in Prognose-/ Beobachtungsplots für beide Zielgrößen (LOLP/EENS) dar. Hierbei wurde das jeweilige MLP-Metamodell ausgewählt, welches zuvor die höchste Prognosegüte an den Validierungsdaten erzielt hat.




Abbildung 38: LOLP/EENS-Prognose-Beobachtungsplot an vier unabhängigen Testszenarien (1.051.200 Testpunkte) [46]

Wie in Abbildung 38 anhand der blauen Datenpunkte visuell ersichtlich, erzielen die Metamodelle eine hohe Prognosegüte an den unabhängigen Testszenarien. Das Bestimmtheitsmaß beträgt für den LOLP-Wert über 0,9999 und für den EENS-Wert über 0,9998, beide nahe

beim Maximalwert von 1,0. Die roten Datenpunkte stellen die resultierende betragliche relative Abweichung dar. Hierbei ist ersichtlich, dass diese mit sinkenden absoluten Werten ansteigt, sodass z.B. für marginale LOLP-Wert im Bereich weniger Millisekunden die relative Abweichung sehr groß ist. Aus dieser hohen relativen Abweichung resultiert allerdings nur eine geringe absolute Abweichung, sodass die betraglichen relativen Abweichungen für die über die Testszenarien aufsummierten Zielgrößen mit 0,5 % für LOLP-/ EENS-Wert sehr gering sind.

Neben der Prognosegüte ist die Zeitersparnis durch die Metamodellierung gegenüber der reinen Simulationszeit ein wichtiges Bewertungskriterium. Zur Erstellung der Metamodelle für alle Zielgrößen werden lediglich rd. 35 Minuten (inkl. Versuchsplanerstellung, Simulationszeit, Training des neuronalen Netzes und Prognose) benötigt. Die eigentliche Prognosezeit für ein Szenario über 30 Wetterjahre benötigt lediglich wenige Millisekunden. Bis auf die Simulation des Versuchsplanes werden hierbei alle Schritte auf einem Standard-PC durchgeführt. Dem gegenübergestellt beträgt die Dauer der nativen Simulation eines Szenarios auf dem Hochleistungs-Rechencluster der RWTH ohne Metamodellierung rd. 8 Stunden (Kraftwerkspark 2022/23 mit 16 Einflussgrößen). Die benötigte Zeit der einzelnen Schritte zur Erstellung der Metamodelle kann Tabelle 10 entnommen werden.

Tabelle 10: Zeit der einzelnen Schritte zur Erstellung der Metamodelle

Metamodellierungsschritte	Time [min]
Zeit zur Erstellung des Versuchsplans	5.0
Simulationszeit des Versuchsplanes (HPC)	12.8
Trainingszeit (2 MLP für LOLP und EENS; jeweils eine Optimierung)	17.8
Prognosezeit (LOLP, LOLE und EENS pro Szenario)	<0.01
Gesamt	35.6

Darüber hinaus ist das Metamodell dazu in der Lage, sämtliche Szenarien innerhalb der Grenzen des Versuchsraumes, in denen das Metamodell Gültigkeit besitzt, zu prognostizieren. Das Metamodell benötigt für die Prognose eines einzelnen Szenarios lediglich wenige Millisekunden, sodass das Metamodell eine hohe Anzahl von Szenarien (z.B. 1000) in rd. 35 Minuten (inkl. Zeit zur Erstellung der Metamodelle) auf einem Standard-PC prognostizieren konnte. Somit steigt der Zeitvorteil beim Einsatz der Metamodellierung drastisch mit der Anzahl an benötigten Szenarien an. Bei der Erstellung des Versuchsplanes müssen hierfür lediglich die Grenzen in Abhängigkeit der später zu prognostizierenden Szenarien gewählt werden. Somit ermöglicht die Anwendung der Metamodellierung tiefgreifende ergebnisintensive Analysen für rechenintensive Simulationsmodelle, wie beispielsweise Multikriterielle Optimierungen, für welche zehntausende Szenarien benötigt werden. Die benötigte Zeit zur Generierung von Ergebnissen (1 bis 1000 Szenarien) wird für die native Simulation und für die Metamodellierung in Abbildung 39 gegenübergestellt.




Abbildung 39: Vergleich des Zeitaufwand bei nativer Simulation und Verwendung von Metamodellierung [46]

Die vorstehenden Ergebnisse zielten auf eine möglichst starke Reduktion der Versuchsplangröße bei einer gleichzeitig akzeptablen Prognosegüte hin. Vor dem Hintergrund der starken Zeitreduktion, insbesondere bei ergebnisintensiven Analysen, besteht die Möglichkeit zur Steigerung der Prognosegüte bei gleichzeitiger Erhöhung der benötigten Zeit zur Erstellung der Metamodelle. Dies kann z.B. über eine weitere Erhöhung der Trainingsdaten erfolgen, wobei die in Kapitel 4.3.1 vorgestellte statistische Methode zur Abtastung des Versuchsraumes verwendet werden muss. Darüber hinaus müssen weiterhin Maßnahmen gegen potenzielles *Overfitting* (Training mit Validierungsdaten, Dropout-Schichten etc.) getroffen werden sowie eine Überprüfung der Prognosegüte anhand unabhängiger Testdaten. Weitere Möglichkeiten ergeben sich durch das sogenannte *Bagging*. Hierbei wird beispielsweise zur Prognose der Mittelwert mehrerer Prognosemodelle, welche mit unterschiedlichen Regressionsmethoden erstellt wurden, verwendet oder es werden einzelne Metamodelle für bestimmte Wertebereiche der Zielgrößen erstellt. Durch die Aufteilung des Wertebereiches auf mehrere Metamodelle wird die Komplexität des Regressionsproblems reduziert. Dies könnte sich vorteilhaft auf die Prognose des schwer zu prognostizierenden Bereiches mit marginal kleinen Werten auswirken. Des Weiteren ändert sich die Dimensionalität des Regressionsproblems von 16 auf 14 Dimensionen durch den Wegfall der Kernenergie je nach Szenario. Hierbei reduziert sich wiederum die Komplexität des Regressionsproblems, wodurch die Prognosegüte durch gesonderte 14 dimensionale Metamodelle verbessert werden könnte.

5 Fallstudie

Die methodischen Erkenntnisse des Projektes KIVi werden innerhalb mehreren Fallstudien erfolgreich angewandt, um die Bewertungen der Versorgungssicherheit in Deutschland und Europa auf Basis realer Szenarien durchführen zu können. Eine im Januar 2023 erschienene Studie mit dem Titel *„Kurzstudie: Verbessert die Laufzeitverlängerung der verbleibenden Kernkraftwerke bis zum 15. April 2023 die Versorgungssicherheit mit Elektrizität?“* befasst sich mit den Auswirkungen des hinausgezögerten Kernenergieausstiegs in Deutschland auf die Versorgungssicherheit mit Elektrizität [88]. Diese wird im Folgenden kurz vorgestellt, wobei der inhaltliche Fokus auf der Anwendung der im Projekt KIVi entwickelten Methoden und deren Ergebnisse liegt.

Hintergrund

Mit dem Wegfall der Erdgaslieferungen aus Russland wuchsen in Deutschland die Bedenken vor möglichen kritischen Situationen bei der Elektrizitätsversorgung. Im Sommer 2022 wurden diese Bedenken durch den gleichzeitigen Ausfall von zeitweise bis zu 32 der insgesamt 56 Kernreaktoren in Frankreich sowie Einschränkungen bei Steinkohlelieferungen infolge sehr niedriger Flusspegel verstärkt [89]. Mit Blick auf den Winter 2022/2023 hat der Deutsche Bundestag deshalb am 11. November 2022 den Weiterbetrieb der letzten drei verbleibenden deutschen Kernkraftwerke Emsland, Isar 2 und Neckarwestheim 2 bis zum 15. April 2023 beschlossen. Damit wird der ursprünglich für den 31. Dezember 2022 beschlossene Kernenergieausstieg um dreieinhalb Monate hinausgezögert.

Ziel der vorliegenden Fallstudie ist die Analyse möglicher Veränderungen der Versorgungssicherheit im Stromsektor infolge des Weiterbetriebs der verbleibenden drei Kernkraftwerke über diesen Zeitraum. Versorgungssicherheit ist hier im Sinne der Fähigkeit des Stromsystems zu verstehen, erwartbare Lastsituationen bedienen zu können. Für die Untersuchungen werden probabilistische Simulationen der Versorgungssicherheit über den Zeitraum des Weiterbetriebs vom 1. Januar 2023 bis zum 15. April 2023 unter Berücksichtigung verschiedener Unsicherheitsfaktoren durchgeführt. [88]

Probabilistische Simulation der Versorgungssicherheit

Zur Untersuchung der Versorgungssicherheit wird das im Projekt KIVi entwickelte probabilistische Simulationsmodell verwendet [34]. Dieses berücksichtigt ausfallbedingte Unsicherheiten und bildet stundenscharf die Erfolgswahrscheinlichkeit ab, dass ein Kraftwerkspark erwartbare Stromlasten decken kann. Der den Analysen zugrundeliegende deutsche Kraftwerkspark kann Abbildung 40 entnommen werden [90].




Abbildung 40: Aggregierter deutscher Kraftwerkspark, basierend auf Kraftwerksliste der BNetzA vom 25.11.2022 [90]

Das Simulationsmodell verarbeitet hierfür eine Vielzahl an technoökonomischen Eingangsdaten, wie bspw. die blockscharfe verfügbare Erzeugungsleistung der installierten Kraftwerke. Außerdem werden Unsicherheiten hinsichtlich der Einspeisemenge erneuerbarer Energien, der Höhe der Stromverbräuche bspw. infolge von verschiedenen Wetterausprägungen sowie möglichen Importbeiträgen aus dem europäischen Ausland berücksichtigt (vgl. Abbildung 41).




Abbildung 41: Zeitreihen der elektrischen Last (links) und des Importpotenzials (rechts) für jeweils 30 Wetterjahre

Insgesamt werden sowohl für die Laufzeitverlängerung sowie für die Stilllegung aller Kernkraftwerke zu Ende 2022 jeweils 30.000 mögliche Szenariovarianten simuliert und verglichen. Die Anzahl der Szenarien setzt sich zusammen aus der Abbildung von 30 möglichen Wetterausprägungen sowie 1.000 sogenannten Monte-Carlo-Permutationen zur Berücksichtigung darüberhinausgehender Unsicherheiten bei der Erdgasversorgung, Stromimporten aus dem

europäischen Ausland sowie Höhe der tatsächlichen Stromnachfrage. Zur Beschleunigung der Modelldurchläufe werden die im Projekt KIVI entwickelte Metamodelle auf Basis künstlich neuronaler Netze eingesetzt [39,43]. Auf Grundlage dieser Simulationen werden die Veränderungen der beiden energiewirtschaftlichen Kennzahlen Loss of Load Expectation (LoLE) und Expected Energy not Served (EEnS) analysiert. Die Kennzahl LoLE gibt die kumulierte Dauer an, in der die erwartete Stromlast nicht vollständig gedeckt werden kann. Die Kennzahl EEnS stellt die aggregierte elektrische Energiemenge dar, die im Untersuchungszeitraum mittels des installierten Kraftwerksparks sowie der Importpotenziale aus dem europäischen Ausland nicht bedient werden kann. [88]

Auswirkungen der Laufzeitverlängerung auf die Versorgungssicherheit mit Elektrizität

Die Auswertung der Simulationsergebnisse zeigt, dass die Laufzeitverlängerung der drei Kernkraftwerke zu einem signifikant höheren Niveau an Sicherheit in der Stromversorgung führt. So sinkt die Unterversorgungsdauer (LoLE) über den dreieinhalbmonatigen Verlängerungszeitraum durch die Laufzeitverlängerung im Durchschnitt um 1,3 Stunden und die Energiefehlmenge (EEnS) im Durchschnitt um 4,3 Gigawattstunden (Millionen Kilowattstunden). Aufgrund von bspw. meteorologischen Unsicherheiten können jedoch auch Szenarien eintreten, in denen die Beiträge der Laufzeitverlängerung auf die Versorgungssicherheitssituation insgesamt niedriger oder höher ausfallen. Je nach Szenario beträgt die Abnahme für die Unterversorgungsdauer (LoLE) durch die Laufzeitverlängerung zwischen 0,0 und 3,2 Stunden sowie für die Abnahme der Energiefehlmenge (EEnS) zwischen 0,0 und 12,1 Gigawattstunden im 5 %- und 95 %-Konfidenzintervall, siehe Abbildung 42. Dargestellt ist der Unterschied zwischen der Versorgungssicherheitssituation mit und ohne Laufzeitverlängerung. Ein negativer Wert bedeutet ein höheres Niveau an Versorgungssicherheit durch die Laufzeitverlängerung.





Abbildung 42: Loss of Load Expectation (LoLE) und Expected Energy not Served (EEnS) mit und ohne AKW-Laufzeitverlängerung bis 14. April 2023

Der zeitlichen Verlauf der erwarteten Lastunterdeckung (EEnS, Expected Energy not Served) für das Szenario mit Laufzeitverlängerung (Variante A) und das Szenario ohne Laufzeitverlängerung (Variante B) der verbleibenden Kernkraftwerke kann Abbildung 43 entnommen werden.

Variante A:
AKW-Laufzeitverlängerung
bis zum 15. April 2023

Median: 11,4 GWh/a
IQA: 5,5 – 21,3 GWh/a

IQA: Interquartilsabstand



Variante B:
Ohne AKW-Laufzeit-
verlängerung nach 2022

Median: 16,1 GWh/a
IQA: 8,6 – 26,9 GWh/a

IQA: Interquartilsabstand




Abbildung 43: Zeitlicher Verlauf der erwarteten Lastunterdeckung der beiden Szenarien

Implikationen und Handlungsempfehlungen

Die Ergebnisse der Simulationen untermauern, dass der Weiterbetrieb der drei verbliebenen Kernkraftwerke Emsland, Isar 2 und Neckarwestheim 2 das Niveau der Versorgungssicherheit mit Elektrizität im Untersuchungszeitraum vom 1. Januar bis zum 15. April 2023 erhöht. Die vorliegenden Analysen beschränken sich aber nur auf die physikalische Versorgungssicherheit mit Elektrizität. Weitere Aspekte werden im Rahmen dieser Studie nicht eingehend untersucht. Eine qualifizierte Entscheidung über die Laufzeiten von Kernkraftwerken erfordert allerdings ein gesellschaftliches Abwägen sämtlicher damit einhergehenden Folgen. So sollte die Analyse der physikalischen Versorgungssicherheit dringend auch um eine Untersuchung der damit resultierenden volkswirtschaftlichen Effekte erweitert werden.

Darüber hinaus sollten insbesondere auch Auswirkungen einer Laufzeitverlängerung auf die Versorgungssicherheit mit Erdgas und anderen Energieträgern, Energiepreisen, CO₂-Emissionen, Risiken für Reaktorunfälle, möglicherweise zusätzlich anfallende radioaktive Abfälle sowie die Akzeptanz der Bevölkerung sorgfältig untersucht und miteinander abgewogen werden. [88]

6 Zusammenfassung und Ausblick

6.1 Zusammenfassung

Die Bedeutung der Bewertung der Versorgungssicherheit mit Elektrizität in Deutschland steigt im Kontext von Liberalisierung und Energiewende: Der gestiegene Wettbewerbsdruck im Zuge der Liberalisierung der Energiemärkte führt zu verminderten Investitionsanreizen in Spitzenlastkapazitäten. Gleichzeitig werden die historisch aufgebauten Überkapazitäten frei verfügbarer thermischer Kraftwerke im Rahmen der Energiewende abgebaut und durch fluktuierend einspeisende erneuerbare Elektrizitätserzeugungsanlagen ersetzt. Auch die Verbreitung von Sektorenkopplungstechnologien und die damit einhergehende zunehmende Elektrifizierung des Energiesystems erhöht die Bedeutung einer zuverlässigen Elektrizitätsversorgung und damit umfassender und wissenschaftlich fundierter Untersuchungen.

Angesichts dieser zunehmenden Relevanz von Untersuchungen zur Versorgungssicherheit wird gezeigt, dass sich nicht nur der Bedarf nach adäquaten Modellen zur Bewertung der Versorgungssicherheit mit Elektrizität erhöht, sondern sich auch die Anforderungen an diese Modelle steigern: Einhergehend mit der steigenden Vielfalt, Konnektivität und Dynamik im Energiesystem steigt auch die Modellkomplexität durch die Abbildung dieser Zusammenhänge. Der in Europa generell zu beobachtende und im Rahmen der Methodology for the European Resource Adequacy Assessment (ERAA Methodik, vgl. ACER, 2020) geforderte Trend hin zu komplexeren, probabilistischen Modellierungsansätzen für die Bewertung der Versorgungssicherheit wird als prinzipiell angebracht angesehen und trägt der zunehmenden Komplexität des Energiesystems Rechnung.

Basierend auf einem Vergleich von deterministischen Kapazitätsbilanzen sowie komplexen, probabilistischen Simulationsmodellen zur Modellierung der Versorgungssicherheit wird das Projektteam mit dem sog. Komplexitätsdilemma konfrontiert: Die Abbildung des komplexen Energiesystems zur Beantwortung anspruchsvoller Forschungsfragen im Zusammenhang mit der Versorgungssicherheit mit Elektrizität erfordert zunehmend komplexe Modelle. Die Genauigkeit dieser komplexen Modelle hängt jedoch wiederum stark von der Qualität der Eingangsdaten ab. Unsicherheiten innerhalb der erforderlichen Datenbasis für komplexe Modelle und insbesondere für Zukunftsszenarien sind erheblich. Zudem basieren Prognosen künftiger Systemzustände immer auf historischen Daten und sind daher insbesondere in Zeiten rascher Transformationen mit großen Unsicherheiten behaftet. Die Beantwortung komplexer Forschungsfragen, die sich auf zukünftige Entwicklungen beziehen, ist daher nur bedingt möglich und es müssen hohe Unsicherheitsbänder bezüglich der Modellergebnisse berücksichtigt werden. Gleichzeitig schränken komplexe Modelle die Anzahl der zu betrachtenden Szenarien und Parametervariationen erheblich ein, sodass umfassende Untersuchungen hinsichtlich des vorliegenden Unsicherheitsbands der Ergebnisse bisher nur begrenzt möglich sind.

Die Projektergebnisse zeigen, dass probabilistische Simulationen eine umfassende Abbildung der komplexen energiesystemischen Zusammenhänge ermöglichen. Damit sind allerdings auch erhöhte Kosten hinsichtlich des Modellierungsaufwands, der Durchführbarkeit von Sensitivitätsanalysen und der Interpretierbarkeit der Ergebnisse verbunden. Das im Projekt KIVI entwickelte probabilistische Simulationsmodell zur Bewertung der Versorgungssicherheit mit Elektrizität wird erfolgreich im deutschen und europäischen Kontext angewandt. Vor

dem Hintergrund der wachsenden Unsicherheit hinsichtlich der künftigen Versorgungssicherheit in Mitteleuropa ermöglicht der probabilistische Ansatz, differenzierte Antworten auf die komplexe Frage nach dem Niveau der Versorgungssicherheit zu geben.

Im Bereich der Datenkonsolidierung und Prognose zeigen die Projektergebnisse, dass Deep Learning (DL)-Methoden ein großes Potenzial zur Datenaufbereitung, d.h. Prognose von Lücken in unvollständigen Datensätzen (Short Term Forecasting), und zur Langzeitprognose (Long Term Forecasting) für Randbedingungen der Versorgungssicherheitsbewertung mit Elektrizität besitzen. Neben einer guten Generalisierung zeichnen sich DL-Methoden insbesondere dadurch aus, große Datenmengen gut verarbeiten zu können. Zur Prognose von unvollständigen Datensätzen kann ein univariater autoregressiver Ansatz aufgrund der kurzen Prognosesequenzen und guten Datenlage der Zielgröße gewählt werden. Am Beispiels des Stromlastganges ist ersichtlich, dass in Abhängigkeit zum Ausmaß der Datenlücken MAPE-Werte zwischen 0,6 % und 5,8 % erreicht werden können. Sollte der konkrete unvollständige Datensatz Datenlücken im Bereich des Long Term Forecasting besitzen, dann sollte ein Lösungsansatz analog zu Langzeitprognosen gewählt werden. Für hochaufgelöste langfristige Prognosen, welche eine hohe Bedeutung für die Versorgungssicherheitsbewertung aufweisen, ist ein nicht autoregressiver multivariater Ansatz aufgrund von Fehlerfortpflanzung und Rechenressourceneinsparung zielführender. Der Methodenvergleich zeigt auch hier das große Potenzial von DL-Methoden, jedoch erzielen auch klassische Regressionsmethoden aus dem Machine Learning (ML)-Bereich, welche um moderne Methoden erweitert wurden, konkurrenzfähige Ergebnisse (SGPR/ XGBoost). Das sogenannte XGBoost erzielt dabei eine etwas geringere Prognosegüte als die DL-Methoden und SGPR, allerdings benötigt diese Methode weniger Expertise und ist leichter zu optimieren.

Um eine adäquate Modellierung der Versorgungssicherheit mit Elektrizität unter Berücksichtigung des Komplexitätsdilemmas zu ermöglichen, wurde daraufhin das Konzept der Metamodellierung unter Verwendung einer effizienten statistischen Versuchsplanung, dem Design of Experiments, eingeführt. Dabei wurde gezeigt, dass Metamodellierung in Verbindung mit einer geeigneten statistischen Versuchsplanung die Möglichkeit bietet, die Ergebnisse detaillierte probabilistischer Modelle zur Versorgungssicherheitsbewertung mit Elektrizität effizient und sehr genau anzunähern. Sie ermöglichen sowohl die Abbildung des komplexen Energiesystems mit einem sehr hohen Detailgrad als auch die Durchführung einer großen Anzahl von Sensitivitätsuntersuchungen zur Abdeckung der bestehenden Unsicherheitsbänder durch eine Vielzahl an Szenario- und Parametervarianten.

Die Projektergebnisse zur Metamodellierung zeigen, dass eine direkte Prognose der Kennzahlen der Versorgungssicherheitsbewertung mit Elektrizität basierend auf probabilistischen Simulationsmodellen durch eine individuell angepasste Approximation mittels ML-Methoden möglich ist. Zur Reduktion der Trainingsdaten und der damit verbundenen Simulationszeit muss der Versuchsraum möglichst effektiv abgetastet werden. Aufgrund der spezifischen Beschaffenheit der Zielgröße LOLP (Begrenzung zwischen 0 und 1) muss hierbei eine Klassifikation angewendet werden. Die erstellten Metamodelle erzielen eine hohe Reduktion der Zeit, welche zur Generierung der Ergebnisse benötigt wird, bei einer guten Prognosegüte. Aufgrund der hohen Dimensionalität des Metamodellierungsproblems performen künstliche neuronale Netze aus dem DL-Bereich besser als klassische ML-Methoden (z.B. Gauß Pro-

zess Regression). Methoden zur Dimensionsreduktion (z.B. Autoencoder) haben das Potenzial die Performance klassischer ML-Methoden bei hoher Dimensionsanzahl zu verbessern, allerdings konnte bei der vorliegenden Metamodellierungsproblematik keine zu DL-Methoden konkurrenzfähigen Ergebnisse erzielt werden. Ein Vergleich unterschiedlicher DL-Methoden hat gezeigt, dass RNN gegenüber FFNN lediglich eine geringfügig bessere Prognosegüte erzielen, jedoch eine wesentlich höhere Trainingszeit aufweisen.

Zur Erstellung der Metamodelle werden rd. 35 Minuten inkl. Versuchsplanerstellung/-simulation und Trainingszeit der künstlichen neuronalen Netzen benötigt. Die Zeit zur Prognose eines beliebigen Szenarios beträgt im Anschluss lediglich wenige Millisekunden. Mit Ausnahme der Simulation des Versuchsplanes beziehen sich die Zeitangaben auf die Nutzung eines Standard Office-PC. Dem gegenüber benötigt die native Simulation mittels probabilistischem Simulationsmodell für ein Szenario rd. 8 Stunden unter Verwendung eines Hochleistungsrechenclusters, sodass die Zeitreduktion mittels Metamodellierung mindestens 92,7 % beträgt. Ferner erhöht sich die Zeitreduktion mit jedem weiteren Szenario drastisch, da die erstellten Metamodellen alle Szenarien innerhalb des Gültigkeitsbereiches jeweils in wenigen Millisekunden prognostizieren können (siehe Abbildung 39). Die hier durchgeführten Arbeiten zielten auf eine möglichst hohe Zeitreduktion bei gleichzeitig hoher Prognosegüte unter Verwendung von MLP ab. Vor dem Hintergrund der erzielten hohen Zeitreduktion, insbesondere bei ergebnisintensiven Analysen mit vielen Szenarien, besteht das Potenzial zur weiteren Steigerung der Prognosegüte. Dies kann u.a. durch eine Vergrößerung des Trainingsdatensatzes unter der Verwendung der vorgestellten Methode zur Abtastung des Versuchsraumes oder durch Bagging-Methoden erzielt werden. Die damit verbundene Erhöhung der zur Erstellung der Metamodelle benötigten Zeit ist sowohl absolut als auch im Vergleich zur anschließenden Zeitersparnis bei der Szenarienanalyse von untergeordneter Bedeutung.

6.2 Ausblick

Die im Rahmen dieses Projektes „Künstliche Intelligenz zur Untersuchung der Versorgungssicherheit mit Elektrizität“ erzielten Ergebnisse ermöglichen eine fundierte Beantwortung der gestellten Forschungsfragen und leisten einen relevanten Beitrag zum Gelingen der Energiewende. Dennoch ergeben sich aus dem Kontext der Projektergebnisse weiterer Forschungsbedarf.

Die in KIVi vorgestellten Projektergebnisse zeigen deutlich das Potenzial von Metamodellen zur Reduktion der Zeit zur Generierung von Ergebnissen von komplexen rechenintensiven Simulationsmodellen und einer damit einhergehenden zeitlichen Realisierbarkeit von komplexen Analysemethoden. Die Möglichkeiten zur Erweiterung der Analyse der Versorgungssicherheit, welche die Metamodellierungsmethode bietet, überschreiten die bloße Beschleunigung bzw. Erhöhung der Anzahl Szenarien. Die Anwendung von ergebnisintensiven Analysemethoden, wie z.B. multikriterielle Optimierungen, sind nun in einer realisierbaren Zeitspanne möglich. Bei multikriteriellen Optimierungen können mehrere Zielgrößen, welche gegenläufige Optima aufweisen, optimiert werden. Aufgrund der gegenläufigen Optima einzelner Zielgrößen weisen solche Optimierungsprobleme eine Vielzahl an Optima auf, welche z.B. über eine Pareto-Optimierung ermittelt werden können. Gegenläufige Optima liegen beispielsweise hinsichtlich der Kosten und der Energiesicherheit vor, da z.B. eine Erhöhung der Reservekapazität sowohl die Kosten als auch die Energiesicherheit erhöhen. Eine Erweite-

rung der bestehenden Simulationsmodelle würde eine ganzheitliche Bewertung der Versorgungssicherheit, d.h. Wirtschaftlichkeit, Nachhaltigkeit und Energiesicherheit, sowie Optimierung des Kraftwerksparks Deutschlands ermöglichen. Darüber hinaus besteht aufgrund der Metamodellierungsmethode auch die Möglichkeit, die Komplexität des zugrundeliegenden Simulationsmodells (z.B. Auflösung etc.) zu erhöhen, da die Rechenintensität kein limitierender Faktor für die Analyse mehr ist.

Die Metamodellierungsmethodik wird im KIVI-Projekt auf ein probabilistisches Simulationsmodell basierend auf dem Prinzip der rekursiven Faltungen, welche eine Verteilungsfunktion der zur Verfügung stehenden gesicherten Einspeiseleistungen des Kraftwerksparks berechnet, angewendet. Das methodische Vorgehen der Metamodellierung muss künftig an alternativen Ansätzen für die probabilistische Bewertung der Versorgungssicherheit mit Elektrizität erprobt und auf die spezifische Metamodellierungsproblemstellung angepasst werden. Zu diesen weiteren Ansätzen zählen z.B. Optimierungsmodelle zur Kraftwerkseinsatzplanung, welche mit einer Monte-Carlo-Simulation gekoppelt werden müssen. Um dem sogenannten Dispatchproblem entgegenzuwirken, ermöglichen diese Optimierungsmodelle, basierend auf einem existierenden Kraftwerkspark, eine Einsatzplanung zu berechnen. Zusätzlich besteht die Möglichkeit, eine Ausbauplanung durchzuführen, die z.B. den kostenoptimalen Ausbau von Erzeugungs-, Speicher- und Netzinfrastrukturen bestimmt, um ein definiertes Niveau an Versorgungssicherheit zu erreichen. Gleichzeitig bieten sie unter anderem die Vorteile, Lastaustausch und (zeitgekoppelten) Speichereinsatz abzubilden und die Einsatzplanung anhand verschiedener Zielgrößen zu optimieren. Die vorstehenden Ansätze entsprechen den aktuellen Anforderungen an die europäische Versorgungssicherheitsbewertung (ACER, 2020). Im Vergleich zu den im KIVI-Projekt verwendeten Simulationsmodellen sind diese Ansätze noch rechenintensiver und weisen dadurch höhere Simulationszeiten auf, wenn der Unsicherheitsraum analog abgebildet werden soll. Die Übertragung der Metamodellierungsmethode weist dadurch ein noch größeres Potenzial auf.

Darüber hinausgehend besteht weiterer Forschungsbedarf in der Erweiterung der entwickelten Methoden und Verfahren hinsichtlich aktueller Anforderungen der europäischen Regulierungsbehörden (vgl. ERAA-Methodik) sowie deren Verbesserung. Bislang fehlt in der Praxis ein branchenweiter Standard für eine komplexitätsgerechte Bewertung der Versorgungssicherheit mit Elektrizität. Die Übertragung der Metamodellierungsmethode und Weiterentwicklung hinsichtlich komplexer Analyse-/ Optimierungsverfahren kann hier Abhilfe schaffen.

7 Weiterverwendung

Fachzeitschriftenartikel

- L. Nolting et al. (2020). Can energy system modeling benefit from artificial neural networks? Application of two-stage metamodels to reduce computation of security of supply assessments. Computers & Industrial Engineering Elsevier. <https://doi.org/10.1016/j.cie.2020.106334>
- Nolting, L. et al. (2020). The complexity dilemma – Insights from security of electricity supply assessments. Energy, 122522. <https://doi.org/10.1016/j.energy.2021.122522>
- C. Brehm et al. (2020). How to model European electricity load profiles using artificial neural networks. Applied Energy Elsevier. <https://doi.org/10.1016/j.apenergy.2020.115564>
- Nolting, L. and Praktiknjo, A. (2020). Can we phase-out all of them? Probabilistic assessments of security of electricity supply for the German case. Applied Energy, Vol. 263, p. 114704. <https://doi.org/10.1016/j.apenergy.2020.114704>
- Köhnen, C. et al. (2021). The potential of deep learning to reduce complexity in energy system modeling. International Journal of Energy Research. <https://doi.org/10.1002/er.7448>
- Priesmann, J. et al. (2023). Kurzstudie: Verbessert die Laufzeitverlängerung der verbleibenden Kernkraftwerke bis zum 15. April 2023 die Versorgungssicherheit mit Elektrizität? Lehrstuhl für Energiesystemökonomik, E.ON Energy Research Center, RWTH Aachen, Arbeitspapiere energiewirtschaftliche Analysen. [10.18154/RWTH-2023-00623](https://doi.org/10.18154/RWTH-2023-00623)
- J. Priesmann et al. (2024). Artificial Intelligence and Design of Experiments for Resource Adequacy Assessment in Power Systems. Energy Strategy Reviews, 53, 101368. <https://doi.org/10.1016/j.esr.2024.101368>
- J. Münch et al. (2024). Uplifting the Complexity of Analysis for Probabilistic Security of Electricity Supply Assessments using Artificial Neural Networks. Review Process Elsevier Energy and AI; Preprint available: <http://dx.doi.org/10.2139/ssrn.4770407>
- J. Münch et al. (2024). Accelerating the generation of results in the simulative security of electricity supply assessments with machine learning: A comparison of methods. (Konferenzveröffentlichung, 19. SDEWES 2024).

Dissertationen

- L. Nolting (2021). Die Versorgungssicherheit mit Elektrizität im Kontext von Liberalisierung und Energiewende. E.ON Energy Research Center, RWTH Aachen University, ISBN: 978-3-948234-13-3. DOI: [10.18154/RWTH-2021-11628](https://doi.org/10.18154/RWTH-2021-11628)
- J. Münch (2025). Mehrwert von Methoden des Maschinellen Lernens für die simulative Bewertung der Versorgungssicherheit mit Elektrizität. (HSD/ PK NRW).

Abschlussarbeiten

- Masterarbeit: Wetterabhängige Vorhersage von Zeitreihen der Elektrizitätsnachfrage mittels neuronaler Netze. C. Behm, RWTH Aachen, 2019.
- Masterarbeit: Anwendung verschiedener Dekompositionsverfahren und Attention-Mechanismen bei der Auswahl von Merkmalen zur Vorhersage von Energiezeitreihen. X. Li, RWTH Aachen, 2020.
- Masterarbeit: Bewertung und Vergleich von Dekompositionsansätzen zur Komplexitätsreduktion in der Energiesystemmodellierung. S. Wouanwo, RWTH Aachen, 2020.
- Masterarbeit: Anwendungen von Künstlicher Intelligenz in der Energiesystemanalyse. M. Steimke, RWTH Aachen, 2021.
- Masterarbeit: Einsatz von Metamodellen zur Reduzierung der Komplexität bei der Bewertung der Stromversorgungssicherheit. J. Halbe, RWTH Aachen, 2021.
- Masterarbeit: Bewertung der Genauigkeit und Konsistenz von Energiesystemmodellen. N. Schobert, RWTH Aachen, 2021.
- Masterarbeit: Modellierung der (Nicht-)Verfügbarkeiten konventioneller Kraftwerke mit Hilfe von Deep Learning. G. Tréheux, RWTH Aachen, 2022.
- Masterarbeit: Vorhersage von Zeitreihen für die Einspeisung aus Erneuerbaren Energien mit Hilfe von Maschinellem Lernen. F. Menne, RWTH Aachen, 2022.
- Masterarbeit: Prognostizierung von Elektrizitätslastprofilen im Verkehrssektor: Anwendung von Machine Learning auf Zeitreihenanalysen unter Einsatz von räumlich-zeitlichen Nutzenergiegedaten. T. Endrigkeit, RWTH Aachen, 2022.
- Masterarbeit: Hochaufgelöste Langzeitprognosen des grenzüberschreitenden Lastaustausches Deutschlands mittels Methoden des Maschinellen Lernens. D. Dörr, HSD, 2023.
- Masterarbeit: Metamodellierung eines Modells zur Versorgungssicherheitsbewertung Deutschlands mittels Design of Experiments und aktivem Lernen. M. Makowka, HSD, 2023.

Workshops und Präsentationen

- 1. Praxisbeiratstreffen (08.09.2020)
 - Status Quo und aktuelle Herausforderungen in der Bewertung der Versorgungssicherheit mit Elektrizität, RWTH Aachen
 - KIVI - Design of Experiments (DoE), HSD ZIES
- 2. Praxisbeiratstreffen (30.11.2020)
 - JERICO Security of Supply Assessment Module: Ein probabilistisches Modells zur Bewertung der Versorgungssicherheit mit Elektrizität, RWTH Aachen
 - Erste Erkenntnisse zur Anwendung von Metamodellierung im Rahmen von KIVI, HSD ZIES

-
- Modellierung europäischer Lastprofile mit künstlichen neuronalen Netzen, RWTH Aachen
 - 3. Praxisbeiratstreffen (01.06.2021)
 - Prognose von Modelleingangsdaten: Einführung und Überblick zu KI basierten Prognosemodellen, HSD ZIES
 - Prognose von Lastzeitreihen: Vorstellung des im Rahmen von KIVi entwickelten KI Modells zur Prognose europäischer Lastzeitreihen, RWTH Aachen
 - 4. Praxisbeiratstreffen (06.12.2021)
 - Vergleich von Methoden des Maschinellen Lernens zur Metamodellierung, HSD ZIES
 - Methodik und Ergebnisse zur direkten Vorhersage von Kennzahlen für die Versorgungssicherheit mittels Metamodellierung, RWTH Aachen
 - 5. Praxisbeiratstreffen (02.12.2022)
 - Modellbildung Metamodellierung: Vom probabilistischen Modell zum Metamodell, HSD ZIES
 - Szenarioanalyse mittels Metamodellierung: Exemplarische Ergebnisse für das Kalenderjahr 2023, RWTH Aachen
 - Abschlussworkshop (18.03.2024)
 - Recap: Überblick und Highlights des Forschungsprojekts KIVi, RWTH Aachen
 - Deep dive: Metamodellierung komplexer probabilistischer Energiesystemmodelle, HSD ZIES
 - Nolting, L., Praktiknjo, A. (2019). Can We Phase-out all of them? How Market Interventions Impact Security of Supply in Germany. 16th International Association for Energy Economics (IAEE) European Conference (IAEE2019), 25.-28. August 2019, Ljubljana, Slovenia.
 - Priesmann J., Nolting L., Praktiknjo A. (2019). Are Complex Energy System Models More Accurate? An Intra-Model Comparison of Energy System Optimization Models. 42nd International Association for Energy Economics (IAEE) Annual Conference in Montréal (IAEE2019), 29. Mai - 1. Juni 2019, Montréal, Kanada.
 - Nolting, L., Praktiknjo, A. (2019). Is the More Complex Model Always the Better One? Evidence from the Assessment of Security of Electricity Supply. ENERDAY 2019 – 13th International Conference on Energy Economics and Technology, 12. April, Dresden, Deutschland.
 - Nolting, L., Praktiknjo, A. (2020). A Guideline to Identify Optimal Levels of Complexity in Energy System Models - Insights from Security of Supply Assessments. International Ruhr Energy Conference (INREC) 2020, 9.-10. September, 2020, Essen, Deutschland (Online Konferenz).
 - Nolting, L., Praktiknjo, A. (2021). How to adequately model security of electricity supply in Germany in the context of energy transition and liberalization. 10th International

Ruhr Energy Conference (INREC), 15.-16. September, Essen, Deutschland (Online Konferenz).

- Nolting, L. et al. (2021). Projektportrait: Künstliche Intelligenz zur Untersuchung der Versorgungssicherheit mit Elektrizität (KIVI). 4. Jahrestreffen des Forschungsnetzwerks Energiesystemanalyse, 18.-20. Mai 2021, Berlin, Deutschland (Online Konferenz).
- J. Münch (2021), Nutzen von Methoden der Künstlichen Intelligenz für die Bewertung der Versorgungssicherheit mit Elektrizität. HSD Machine Learning Kolloquium 2021, Düsseldorf, Deutschland.
- J. Priesmann et al. (2022), Künstliche Intelligenz zur Untersuchung der Versorgungssicherheit mit Elektrizität – Expertenbefragung zur Abbildung von Modelldetails und Unsicherheiten (6. Jahrestreffen des Forschungsnetzwerks Energiesystemanalyse 2022).
- B. Prusas (2022): Simulation of Germany's security of supply: long-term forecasting of electric load profiles using machine learning. ENERDAY 2022 - 16th international conference of energy economics and technology, 30.9.2022, Dresden, Germany.
- Priesmann, J., Nolting, L., Praktiknjo, A. (2023). Using metamodels for conducting large-scale scenario analyses: The case of security of electricity supply. 13. Internationale Energiewirtschaftstagung (IEWT 2023). February 15-17, Vienna, Austria.
- Tillmanns, M., Priesmann, J., Menne, F., Praktiknjo, A. (2023). Time series forecasting for electricity generation from variable renewable energies - A hybrid approach with analytical models and machine learning. 13. Internationale Energiewirtschaftstagung (IEWT 2023). February 15-17, Vienna, Austria.
- Daun, P., Tillmanns, M. et al. (2023): Artificial intelligence for assessing the security of electricity supply: Study - Nuclear Power Plants in Germany. 18. IAEE European Conference, 2023-07-24 - 2023-07-27, Milan, Italy.
- D. Dörr (2024), Hochaufgelöste Langzeitprognose des deutschen Strom-Importpotenzials mithilfe von Methoden des Maschinellen Lernens. RET.Con 2024 - 7. Regenerative Energietechnik Konferenz, Nordhausen, Germany.
- J. Münch (2024), "Accelerating the generation of results in the simulative security of electricity supply assessments with machine learning: A comparison of methods". SDEWES 2024 - The 19th Conference on Sustainable Development of Energy, Water and Environment Systems, 08.09 - 12.09.2024, Rom, Italy.

8 Literaturverzeichnis

- [1] entso-e. Scenario Outlook & Adequacy Forecast 2015.
- [2] German Transmission System Operators. Abschlussbericht - Systemanalysen 2018 (Final report - system analyses 2018) 2018.
- [3] BNetzA. Quality of supply 2018. <https://goo.gl/8epqoo> (accessed January 22, 2019).
- [4] Agora Energiewende. Kohleausstieg, Stromimporte und -exporte sowie Versorgungssicherheit (Coal phase-out, electricity imports/exports and security of supply) 2017.
- [5] Energy Brainpool. Kurzanalyse - Bedarf nach einer Kapazitätsreserve aus Kohlekraft im Deutschen Markt bis 2023 (Short analysis - Demand for a reserve capacity from coal-fired power plants in the German market until 2023) 2015.
- [6] Öko-Institut, LBD Beratungsgesellschaft, RAUE LLP. Fokussierte Kapazitätsmärkte. Ein neues Marktdesign für den Übergang zu einem neuen Energiesystem (Focused capacity markets. A new market design for the transition to a new energy system) 2012.
- [7] Prognos. Security of supply: a pan-European approach 2015.
- [8] entso-e. Mid-Term Adequacy Forecast 2017 2017.
- [9] Pentilateral Energy Forum. Generation Adequacy Assessment 2018.
- [10] Consentec, r2b energy consulting. Versorgungssicherheit in Deutschland und seinen Nachbarländern: länderübergreifendes Monitoring und Bewertung (Security of supply in Germany and its neighbouring countries: international monitoring and evaluation) 2015.
- [11] EICOM. System Adequacy 2020 2017.
- [12] Meeus L, Nouicer A. The EU Clean Energy Package 2018.
- [13] Deutsches Zentrum für Luft- und Raumfahrt (DLR, Projektkoordinator). Beam-Me Projekt homepage 2019.
- [14] Forschungszentrum Jülich GmbH (Projektkoordinator). METIS Plattform 2019.
- [15] Montgomery DC, Peck EA, Vining GG. Introduction to linear regression analysis. vol. 821. John Wiley & Sons; 2012.
- [16] Kleinbaum D, Kupper L, Nizam A, Rosenberg E. Applied regression analysis and other multivariable methods. Nelson Education; 2013.
- [17] Montgomery DC. Design and analysis of experiments. John Wiley & Sons; 2017.
- [18] Zurada J.M. Introduction to artificial neural systems. vol. 8. West publishing company St. Paul; 1992.

-
- [19] Aiolli F, Biehl M, Oneto L. Advances in artificial neural networks, machine learning and computational intelligence. *Neurocomputing* 2018;298:1–3. doi:10.1016/j.neucom.2018.01.090.
- [20] Reich M, Adam M, Lambach S. Comparison of different Methods for Approximating Models of Energy Supply Systems and Polyoptimising the Systems-Structure and Components-Dimension. 30th International Conference on Efficiency, Cost, Optimisation, Simulation and Environmental Impact of Energy Systems (ECOS), 2017.
- [21] Biedermann T, Reich M, Kameier F, Adam M, Paschereit C. Assessment of Statistical Sampling Methods and Approximation Models Applied to Aeroacoustic and Vibroacoustic Problems. INTER-NOISE and NOISE-CON Congress and Conference Proceedings, vol. 257, Institute of Noise Control Engineering; 2018, p. 13–24.
- [22] Pfenninger S, DeCarolis J, Hirth L, Quoilin S, Staffell I. The importance of open data and software: Is energy research lagging behind? *Energy Policy* 2017;101:211–5. doi:10.1016/j.enpol.2016.11.046.
- [23] Neon Neue Energieökonomik GmbH (Projektkoordinator). Open Power System Data Website 2019.
- [24] ENTSO-E. Transparency Platform 2019.
- [25] EPEX SPOT. Market Data Platform 2019.
- [26] Debnath KB, Mourshed M. Forecasting methods in energy planning models. *Renewable and Sustainable Energy Reviews* 2018;88:297–325. doi:10.1016/j.rser.2018.02.002.
- [27] Srinivasan D, Lee MA. Survey of hybrid fuzzy neural approaches to electric load forecasting. 1995 IEEE International Conference on Systems, Man and Cybernetics. Intelligent Systems for the 21st Century, vol. 5, IEEE; 1995, p. 4004–8.
- [28] Hong T, Fan S. Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting* 2016;32:914–38.
- [29] Esteves GR, Bastos BQ, Cyrino FL, Calili RF, Souza RC. Long term electricity forecast: a systematic review. *Procedia Computer Science* 2015;55:549–58.
- [30] Alfares HK, Nazeeruddin M. Electric load forecasting: literature survey and classification of methods. *International Journal of Systems Science* 2002;33:23–34.
- [31] Hobbs BF, Jitprapaikulsarn S, Konda S, Chankong V, Loparo KA, Maratukulam DJ. Analysis of the value for unit commitment of improved load forecasts. *IEEE Transactions on Power Systems* 1999;14:1342–8.
- [32] BNetzA. Feststellung des Bedarfs an Netzreserve für den Winter 2018/2019 sowie das Jahr 2020/2021 (Determination of the need for grid reserve for winter 2018/ 2019 and year 2020/2021); 2018.

-
- [33] Coester A, Hofkes MW, Papyrakis E. Economics of renewable energy expansion and security of supply: a dynamic simulation of the German electricity market. *Appl Energy* 2018;231:1268–84. <https://doi.org/10.1016/j.apenergy.2018.09.143>.
- [34] Nolting, L., Praktiknjo, A., 2020. Can we phase out all of them? Probabilistic assessments of security of electricity supply for the German case. *Applied Energy*, 263, 114704.
- [35] entso-e. Mid-Term Adequacy Forecast 2018; 2018.
- [36] frontier economics, FORMAET Services. Strommarkt in Deutschland - Gewährleistet das derzeitige Marktdesign Versorgungssicherheit? (Electricity market in Germany - Does the current market design guarantee security of supply?) 2014.
- [37] Praktiknjo A, Dittmar L. Optimal Level of Supply Security in the Power Sector with Growing Shares of Fluctuating Renewable Energy. *Energy: Expectations and Uncertainty*, 39th IAEE International Conference, Jun 19-22, 2016, International Association for Energy Economics; 2016.
- [38] DLR, IER. Szenarien der Versorgungssicherheit in Deutschland und Süddeutschland (Scenarios of supply security in Germany and Southern Germany); 2016.
- [39] Nolting, L. (2021). Die Versorgungssicherheit mit Elektrizität im Kontext von Liberalisierung und Energiewende. Dissertation. E.ON Energy Research Center, RWTH Aachen University. ISBN: 978-3-948234-13-3.
- [40] Priesmann J, Münch J, Ridha E, Spiegel T, Reich M, Adam M, et al. Artificial Intelligence and Design of Experiments for Assessing Security of Electricity Supply: A Review and Strategic Outlook. *CoRR* 2021;abs/2112.04889.
- [41] Nolting, L., Praktiknjo, A. (2022). The Complexity Dilemma – Insights from Security of Electricity Supply Assessments. *Energy*, 122522.
- [42] Pambour KA, Cakir Erdener B, Bolado-Lavin R, Dijkema GPJ. SAInt – a novel quasi-dynamic model for assessing security of supply in coupled gas and electricity transmission networks. *Appl Energy* 2017;203:829–57. <https://doi.org/10.1016/j.apenergy.2017.05.142>.
- [43] Priesmann J, Münch J, Tillmanns M, Ridha E, Spiegel T, Reich M et al. Artificial intelligence and design of experiments for resource adequacy assessment in power systems. *Energy Strategy Reviews* 2024;53:101368. <https://doi.org/10.1016/j.esr.2024.101368>.
- [44] Mockenhaupt A. Digitalisierung und Künstliche Intelligenz in der Produktion: Grundlagen und Anwendung. Wiesbaden, Heidelberg: Springer Vieweg; 2021.

-
- [45] Bontempi G, Ben Taieb S, Le Borgne Y-A. Machine Learning Strategies for Time Series Forecasting. In: Aufaure M-A, Zimányi E, editors. Business Intelligence. Berlin, Heidelberg: Springer Berlin Heidelberg; 2013, p. 62–77.
- [46] Münch J, Priesmann J, Reich M, Tillmanns M, Praktijnjo A, Adam M. Uplifting the Complexity of Analysis for Probabilistic Security of Electricity Supply Assessments Using Artificial Neural Networks. <http://dx.doi.org/10.2139/ssrn.4770407>; 2024.
- [47] Montgomery DC. Design and analysis of experiments. Hoboken, NJ: Wiley; 2017.
- [48] Siebertz K, van Bebber D, Hochkirchen T. Statistische Versuchsplanung: Design of Experiments (DoE). 2nd ed. Berlin, Heidelberg: Springer Vieweg; 2017.
- [49] Yates F. The design and analysis of factorial experiments. [March 22, 2024]; Available from: <https://repository.rothamsted.ac.uk/download/da923ac105983581f7731b3062a119a7e690931c120a16aad0550dd9c527e8fe/10768968/The%20Design%20and%20Analysis.pdf>.
- [50] McKay MD, Beckman RJ, Conover WJ. A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code. *Technometrics* 1979;21(2):239. <https://doi.org/10.2307/1268522>.
- [51] Iman RL, Conover WJ. Small sample sensitivity analysis techniques for computer models with an application to risk assessment. *Communications in Statistics - Theory and Methods* 1980;9(17):1749–842. <https://doi.org/10.1080/03610928008827996>.
- [52] Ye KQ. Orthogonal Column Latin Hypercubes and Their Application in Computer Experiments. *Journal of the American Statistical Association* 1998;93(444):1430–9. <https://doi.org/10.1080/01621459.1998.10473803>.
- [53] Botsch B. Maschinelles Lernen - Grundlagen und Anwendungen: Mit Beispielen in Python. Berlin, Heidelberg: Springer Spektrum; 2023.
- [54] Rasmussen CE, Williams CKI. Gaussian processes for machine learning. Cambridge, MA, USA: MIT Press; 2005.
- [55] Pang J, Liu D, Liao H, Peng Y, Peng X. Anomaly detection based on data stream monitoring and prediction with improved Gaussian process regression algorithm. In: 2014 International Conference on Prognostics and Health Management. IEEE; 2014, p. 1–7.
- [56] Reich M, Gottschald J, Riegebauer P, Adam M. Predictive Control of District Heating System Using Multi-Stage Nonlinear Approximation with Selective Memory. *Energies* 2020;13(24):6714. <https://doi.org/10.3390/en13246714>.
- [57] Liu H, Ong Y-S, Shen X, Cai J. When Gaussian Process Meets Big Data: A Review of Scalable GPs. *IEEE Trans Neural Netw Learn Syst* 2020;31(11):4405–23. <https://doi.org/10.1109/TNNLS.2019.2957109>.

-
- [58] Sperstad IB, Degefa MZ, Kjølle G. The impact of flexible resources in distribution systems on the security of electricity supply: A literature review. *Electric Power Systems Research* 2020;188:106532. <https://doi.org/10.1016/j.epsr.2020.106532>.
- [59] Mao Y, Shaoshuai W. A review of wind power forecasting & prediction. In: 2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS): October 16-20, 2016, Beijing, China conference proceedings. Piscataway, NJ: IEEE; 2016, p. 1–7.
- [60] Figgenger J, Stenzel P, Kairies K-P, Linßen J, Haberschusz D, Wessels O et al. The development of stationary battery storage systems in Germany – A market review. *Journal of Energy Storage* 2020;29:101153. <https://doi.org/10.1016/j.est.2019.101153>.
- [61] Koohi-Fayegh S, Rosen MA. A review of energy storage types, applications and recent developments. *Journal of Energy Storage* 2020;27:101047. <https://doi.org/10.1016/j.est.2019.101047>.
- [62] Arteaga J, Zareipour H. A Price-Maker/Price-Taker Model for the Operation of Battery Storage Systems in Electricity Markets. *IEEE Trans. Smart Grid* 2019;10(6):6912–20. <https://doi.org/10.1109/TSG.2019.2913818>.
- [63] Ausfelder F, Beilmann C, Bertau M, Bräuninger S, Heinzel A, Hoer R et al. Energy Storage as Part of a Secure Energy Supply. *ChemBioEng Reviews* 2017;4(3):144–210. <https://doi.org/10.1002/cben.201700004>.
- [64] Campana PE, Cioccolanti L, François B, Jurasz J, Zhang Y, Varini M et al. Li-ion batteries for peak shaving, price arbitrage, and photovoltaic self-consumption in commercial buildings: A Monte Carlo Analysis. *Energy Conversion and Management* 2021;234:113889. <https://doi.org/10.1016/j.enconman.2021.113889>.
- [65] Stephen GW. Impact of Storage Dispatch Assumptions on Resource Adequacy Assessment: Preliminary Work; 2019.
- [66] Scapino L, Zondag HA, Diriken J, Rindt CC, van Bael J, Sciacovelli A. Modeling the performance of a sorption thermal energy storage reactor using artificial neural networks. *Applied Energy* 2019;253:113525. <https://doi.org/10.1016/j.apenergy.2019.113525>.
- [67] Wang H, Yang J, Chen Z, Li G, Liang J, Ma Y et al. Optimal dispatch based on prediction of distributed electric heating storages in combined electricity and heat networks. *Applied Energy* 2020;267:114879. <https://doi.org/10.1016/j.apenergy.2020.114879>.
- [68] Xiao H, Pei W, Deng W, Kong L, Sun H, Tang C. A Comparative Study of Deep Neural Network and Meta-Model Techniques in Behavior Learning of Microgrids. *IEEE Access* 2020;8:30104–18. <https://doi.org/10.1109/ACCESS.2020.2972569>.

-
- [69] Gasser P, Suter J, Cinelli M, Spada M, Burgherr P, Hirschberg S et al. Comprehensive resilience assessment of electricity supply security for 140 countries. *Ecological Indicators* 2020;110:105731. <https://doi.org/10.1016/j.ecolind.2019.105731>.
- [70] Gils HC, Bothor S, Genoese M, Cao K-K. Future security of power supply in Germany- The role of stochastic power plant outages and intermittent generation. *Int J Energy Res* 2018;42(5):1894–913. <https://doi.org/10.1002/er.3957>.
- [71] Bessa RJ. Future Trends for Big Data Application in Power Systems. In: *Big Data Application in Power Systems*. Elsevier; 2018, p. 223–242.
- [72] Hundi P, Shahsavari R. Comparative studies among machine learning models for performance estimation and health monitoring of thermal power plants. *Applied Energy* 2020;265:114775. <https://doi.org/10.1016/j.apenergy.2020.114775>.
- [73] VGB e.V. Verfügbarkeit von Wärmekraftwerken 2007 - 2016 (Availability of Thermal Power Plants 2007 - 2016); 2017.
- [74] EEX. Transparency Platform; 2018 [WWW Document]. URL <https://www.eextranparency.com/>.
- [75] Brückl, O., 2006. Wahrscheinlichkeitstheoretische Bestimmung des Regel- und Reserveleistungsbedarfs in der Elektrizitätswirtschaft (Probabilistic Assessment of Demand for Grid Services and Reserves for Electricity Industry). TU München.
- [76] Ibanez E, Milligan M. Impact of transmission on resource adequacy in systems with wind and solar power. In: *IEEE power and energy society general meeting*; 2012. p. 1–5.
- [77] Behm C, Nolting L, Praktijnjo A. Artificial Intelligence for Long-Term Forecasting of Electricity Demand Time Series. *The Energy Journal* (under Review) 2019.
- [78] entso-e. MAF 2016 Dataset; 2016.
- [79] González Aparicio I, Huld T, Careri F, Monforti F, Zucker A. EMHIRES dataset - Part II: Solar power generation, JRC Science for Policy Report; 2017.
- [80] González Aparicio I, Zucker A, Careri F, Monforti F, Huld T, Badger J. EMHIRES dataset - Part I: Wind power generation, JRC Science for Policy Report; 2016.
- [81] Copernicus. The European Climatic Energy Mixes (ECEM) Demonstrator; 2018 [WWW Document]. URL <http://ecem.wemcouncil.org/#> [accessed 9.6.18].
- [82] Praktijnjo A, Dittmar L. Optimal level of supply security in the power sector with growing shares of fluctuating renewable energy. In: *Energy: expectations and uncertainty, 39th IAEE international conference, Jun 19–22, 2016*. International Association for Energy Economics; 2016.

-
- [83] Wentlent, C., Adamson, A., Clayton, R., Dahl, C., Fedora, P., Gioia, P., Sasson, M., Younger, M., 2020. Resource Adequacy Metrics and their Applications. Bericht der NYSRC Resource Adequacy Working Group, New York, NY, USA, 20. April 2020. Online verfügbar unter: <https://www.nysrc.org/PDF/Reports/Resource%20Adequacy%20Metric%20Report%20Final%204%2020%202020%5B6431%5D.pdf> [zuletzt abgerufen am 20.06.2023].
- [84] BNetzA. Kraftwerksliste (Power plant list); 2018.
- [85] BNetzA. Kraftwerksstilllegungsanzeigenliste (KWSAL) (List of power plant closure notifications); 2018.
- [86] BNetzA, 2017. Netzentwicklungsplan Strom (NEP) (Network development plan electricity).
- [87] Nolting L, Spiegel T, Reich M, Adam M, Praktiknjo A. Can energy system modeling benefit from artificial neural networks? Application of two-stage metamodels to reduce computation of security of supply assessments. *Computers & Industrial Engineering* 2020;142:106334. <https://doi.org/10.1016/j.cie.2020.106334>.
- [88] Priesmann, J. et al. (2023). Kurzstudie: Verbessert die Laufzeitverlängerung der verbleibenden Kernkraftwerke bis zum 15. April 2023 die Versorgungssicherheit mit Elektrizität? Lehrstuhl für Energiesystemökonomik, E.ON Energy Research Center, RWTH Aachen, Arbeitspapiere energiewirtschaftliche Analysen.
- [89] Deutsche Übertragungsnetzbetreiber. Abschlussbericht Sonderanalysen Winter 2022/2023. 2022.
- [90] Bundesnetzagentur. Kraftwerksliste Bundesnetzagentur (bundesweit; alle Netz- und Umspannebenen) Stand 25.11.2022. 2022.

Berichtsblatt

1. ISBN oder ISSN Geplant (wird durch TIB vergeben)	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel KIVI - Künstliche Intelligenz zur Untersuchung der Versorgungssicherheit mit Elektrizität Abschlussbericht	
4. Autor(en) [Name(n), Vorname(n)] Justin Münch, Philipp Daun, Marius Tillmanns, Dominik Dörr, Jan Priesmann Marius Reich, Dr. Lars Nolting, Benedikt Prusas, Prof. Dr.-Ing. Mario Adam, Prof. Dr.-Ing. Aaron Praktiknjo	5. Abschlussdatum des Vorhabens 31.11.2023
	6. Veröffentlichungsdatum 07.06.2024
	7. Form der Publikation Dokument im pdf-Format
8. Durchführende Institution(en) (Name, Adresse) RWTH Aachen University, Lehrstuhl für Energiesystemökonomik (FCN-ESE), Mathieustrasse 10, 52074 Aachen University of Applied Sciences Düsseldorf (Hochschule Düsseldorf), ZIES - Zentrum für Innovative Energiesysteme, Münsterstraße 156, 40476 Düsseldorf	9. Ber. Nr. Durchführende Institution -
	10. Förderkennzeichen 03EI1022A / 03EI1022B
	11. Seitenzahl 85
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 90
	14. Tabellen 10
	15. Abbildungen 43
16. Zusätzliche Angaben -	
17. Vorgelegt bei (Titel, Ort, Datum) -	
18. Kurzfassung Das Energiesystem in Deutschland ist im Zuge der Energiewende von Umbrüchen geprägt: Kernenergieausstieg, Kohleausstieg, Ausbau der erneuerbaren Energien und zunehmende Sektorenkopplung ergeben eine Vielzahl an möglichen Szenarien für das zukünftige Energiesystem und damit einhergehend ein großes Maß an Unsicherheit. Zur adäquaten Versorgungssicherheitsbewertung mit Elektrizität werden komplexe, hochaufgelöste probabilistische Simulationsmodelle benötigt. Die mit der Rechenintensität einhergehenden hohen Rechenzeiten führen zu einem Komplexitätsdilemma zwischen Modelkomplexität und Analysetiefe. Das Forschungsvorhaben KIVI zeigt den großen Nutzen von Methoden des Maschinellen Lernens (ML) zur Datenkonsolidierung/-prognose der zeitlich aufgelösten Randbedingungen sowie zur Metamodellierung probabilistischer Simulationsmodelle für die Versorgungssicherheitsbewertung mit Elektrizität auf. Die Forschungsergebnisse zur Metamodellierung zeigen, dass eine direkte Prognose der Kennzahlen der Versorgungssicherheitsbewertung durch eine individuell angepasste Approximation mittels einer Kombination aus Methoden des ML und statistischer Versuchsplanung möglich ist. Mit diesem Lösungsansatz wird eine starke Zeitreduktion von mindestens 92,7% (bei einem Szenario) und gleichzeitig eine hohe Prognosegüte ($R^2 > 0,9998$) erzielt. Mit jedem weiteren Szenario erhöht sich die Zeitreduktion drastisch, da die erstellten Metamodelle sämtliche Szenarien innerhalb Ihres Gültigkeitsbereiches prognostizieren können, sodass mit jedem weiteren Szenario bei der Verwendung von Metamodellen lediglich wenige Millisekunden hinzukommen. Weiterführende Forschungsarbeiten sollten daher darauf abzielen unter Anwendung von Metamodellen komplexere Analyse-/ Optimierungsverfahren, welche eine Vielzahl an Szenarien voraussetzen, auf die Versorgungssicherheitsbewertung mit Elektrizität anzuwenden und hinsichtlich der spezifischen Anforderungen weiterzuentwickeln.	
19. Schlagwörter Versorgungssicherheitsbewertung mit Elektrizität, probabilistische Simulation, Maschinelles Lernen, Deep Learning, Zeitreihenprognose, Metamodellierung, Regression, statistische Versuchsplanung	
20. Verlag TIB	21. Preis Open Access

Document Control sheet

1. ISBN or ISSN Planned (to be awarded by TIB)	2. type of document (e.g. report, publication) Final report
3. title KIVI - Artificial intelligence for assessing the security of electricity supply Final report	
4. author(s) [surname(s), first name(s)] Justin Münch, Philipp Daun, Marius Tillmanns, Dominik Dörr, Jan Priesmann Marius Reich, Dr. Lars Nolting, Benedikt Prusas, Prof. Dr.-Ing, Prof. Dr.-Ing. Aaron Praktiknjo	5. end of project 31.11.2023 6. publication date 07.06.2024 7. form of publication Document in pdf format
8. performing organization(s) (name, address) RWTH Aachen University, Chair for Energy Systems Economics (FCN-ESE), Mathieustrasse 10, 52074 Aachen University of Applied Sciences Düsseldorf (Hochschule Düsseldorf), ZIES - Center for Innovative Energy Systems, Münsterstraße 156, 40476 Düsseldorf	9. originator's report no. - 10. reference no. 03EI1022A / 03EI1022B 11. no. of pages 85
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 90 14. no. of tables 10 15. no. of figures 43
16. supplementary notes -	
17. presented at (title, place, date) -	
18. abstract The energy system in Germany is characterized by upheavals in the course of the energy transition: nuclear phase-out, coal phase-out, expansion of renewable energies and increasing sector coupling result in a large number of possible scenarios for the future energy system and thus a high degree of uncertainty. Complex, high-resolution probabilistic simulation models are required to adequately assess the security of electricity supply. The high computing times associated with the computational intensity lead to a complexity dilemma between model complexity and depth of analysis. The KIVI research project demonstrates the great benefit of machine learning (ML) methods for data consolidation/forecasting of time-resolved boundary conditions and for metamodeling of probabilistic simulation models for the security of supply assessment with electricity. The research results on metamodeling show that a direct prediction of the key figures of the security of supply assessment is possible through an individually adapted approximation using a combination of ML methods and statistical design of experiments. This approach achieves a significant time reduction of at least 92.7% (for one scenario) and at the same time a high forecast quality ($R^2 > 0.9998$). The time reduction increases drastically with each additional scenario, as the metamodels created can forecast all scenarios within their validity range, so that only a few milliseconds are added with each additional scenario when using metamodels. Further research should therefore aim to use metamodels to apply more complex analysis/optimization procedures, which require a large number of scenarios, to the assessment of security of supply with electricity and to further develop them with regard to the specific requirements.	
19. keywords Assessment of security of electricity supply, probabilistic simulation, machine learning, deep learning, time series forecasting, metamodeling, regression, statistical design of experiments	
20. publisher TIB	21. price Open Access