



Fraunhofer
IEE

Kompetenzzentrum Kognitive Energiesysteme

Künstliche Intelligenz im Energiesektor



Kognitive
Energiesysteme


Künstliche Intelligenz im Energiesektor

Spotlight-Projekte



Inhalt

Grußwort	6
Executive Summary	8
Ausblick	9
Kognitive Energiesysteme	11
Netzbetrieb	12
Prognosen	16
Resilienz	20
Leistungselektronik	24
Energiemanagement	28
Energiehandel	32
Spotlights Übersicht	36
Literaturverzeichnis	39
Begleitkreismitglieder	42
Förderer	43
Ansprechpartner Fraunhofer IEE	44
Impressum	45



Grußwort

Liebe Leserinnen und Leser,

die Energiewende, der Umstieg auf nachhaltige, klima- und umweltschonende Energiesysteme, ist eine Menschheitsfrage. Um die Energiewende zu schaffen, brauchen wir zukunftsweisende Forschung, die Technik kontinuierlich weiterentwickelt.

Die Abkehr von der zentral organisierten und auf fossilen Energieträgern basierenden Kraftwerkswirtschaft hin zu einem dezentralen Energiesystem, das auf erneuerbaren Quellen beruht, ist ein komplexer Prozess. Eine zunehmend dezentrale Energieerzeugung erfordert kognitive Intelligenz, welche die komplexen Prozesse zu lenken und automatisieren vermag. Dieser Herausforderung stellen sich die Wissenschaftlerinnen und Wissenschaftler des Fraunhofer-Instituts für Energiewirtschaft und Energiesystemtechnik IEE in Kassel. Mit dem besonderen Fokus auf künstliche Intelligenz (KI) entwickeln sie in dem Aufbauprojekt Kompetenzzentrum Kognitive Energiesysteme (K-ES) seit Mitte 2020 vielfältige Ansätze kognitiver Prozesse für die Energiesystemtechnik, die Energiewirtschaft sowie die Energienetze. Der Schwerpunkt der Startphase lag auf der Rekrutierung von Wissenschaftlerinnen und Wissenschaftlern und dem Aufbau von Kompetenzen.

Die Hessische Landesregierung hat eine ministeriumsübergreifende Zukunftsagenda für KI entwickelt. Deshalb hat mein Haus den Aufbau des »Kompetenzzentrums Kognitive Energiesysteme« mit einer Anschubfinanzierung von 5,8 Millionen Euro gefördert. Wir freuen uns sehr, dass dieser Anschlag sich in zwei Folgeprojekten fortsetzt. Zum einen einer Förderung für eine Nachwuchsgruppe »RL4CES - Reinforcement Learning for Cognitive Energy Systems« zwischen Universität Kassel und Fraunhofer IEE und zum anderen dem Projekt »KISSKI«, in dem fünf Einrichtungen aus der Mitte Deutschlands erforschen, wie ein »KI-Servicezentrum für sensible und kritische Infrastrukturen« mit den Schwerpunkten Energie und Medizin aufgebaut werden kann.

Ich wünsche Ihnen eine spannende Lektüre und einen interessanten Einblick in die Arbeit der Forscherinnen und Forscher und ihre ambitionierten Projektideen zur Digitalisierung für die erfolgreiche Umsetzung der Energiewende.

Ihre Angela Dorn

Hessische Ministerin für Wissenschaft und Kunst



Künstliche Intelligenz ist eine Schlüsseltechnologie für die weitere Entwicklung der Energiewende.«

Angela Dorn
Hessische Ministerin für
Wissenschaft und Kunst

Executive Summary

Das Energiesystem steht durch Dezentralisierung, Dekarbonisierung und Digitalisierung vor großen Herausforderungen. Künstliche Intelligenz (KI) kann helfen, die steigende Komplexität durch selbstlernende Systeme zu bewältigen und die Betriebskosten durch Automatisierung zu senken. KI kann dafür in vielfältigen Anwendungsbereichen entlang der gesamten Wertschöpfungskette Aufgaben automatisiert übernehmen.

Das Projekt »Kompetenzzentrum Kognitive Energiesysteme« hat zum Ziel, die Grundlagen für den erfolgreichen Einsatz von Künstlicher Intelligenz (KI) im Energiesystem zu schaffen und den Grundstein für die Entwicklung kognitiver Energiesysteme zu legen. KI kann dazu beitragen, Erzeugung, Verbrauch und Speicherung besser zu synchronisieren, die Infrastruktur zuverlässiger zu machen und stochastisches Verhalten durch Prognosen planbarer zu gestalten. Das Kompetenzzentrum verfolgt einen Open-Innovation-Ansatz und hat drei Hauptziele: den Aufbau eines Teams von Experten und Expertinnen mit entsprechenden Werkzeugen (K-ES), den Aufbau eines Innovationsrahmens, in dem Wissenschaft und Wirtschaft gemeinsam Innovationen schaffen können (Ökosystem) und die beispielhafte Demonstration und Veranschaulichung der Möglichkeiten kognitiver Energiesysteme (Spotlights).



Für den erfolgreichen Aufbau von K-ES werden ein agiles Projektmanagement eingesetzt und interdisziplinäre Teams gebildet. Dadurch werden neue Ideen gefördert und Brücken über Fachgrenzen hinweg geschlagen. Das Ökosystem Kognitive Energiesysteme soll einen Rahmen schaffen, in dem Wissenschaft und Wirtschaft gemeinsam das Thema Kognitive Energiesysteme entwickeln und erfolgreich in die Anwendung bringen. Das Projekt schafft dafür die Basis, indem durch regelmäßige Veranstaltungen eine Community aufgebaut und die Öffentlichkeit informiert wird.

Die K-ES Spotlights demonstrieren und veranschaulichen die Potenziale von kognitiven Energiesystemen. In vier Ausschreibungen wurden Mitarbeitende des IEE eingeladen, Vorschläge für Spotlight-Projekte in den drei Kategorien Öffentlichkeitswirksamkeit, Wissenschaftliche Exzellenz und High-Risk / High-Gain vorzuschlagen. Alle Spotlight-Projekte haben eine Laufzeit von sechs Monaten

Das Projekt konnte erfolgreich 50 Mitarbeitende und 16 Nachwuchswissenschaftler und -wissenschaftlerinnen einbinden, 13 wissenschaftliche Veröffentlichungen und 7 öffentliche Demonstrationen entwickeln sowie 17 Folgeprojekte initiieren. Die entwickelten Werkzeuge stehen den Experten und Expertinnen zur Verfügung und können eingesetzt und weiterentwickelt werden. Mit der Konzeptentwicklung zum Innovationscluster für Kognitive Energiesysteme (IC4CES) und dem KI-Servicezentrum für sensible und kritische Infrastrukturen (KISSKI) wurden wichtige institutionelle Förderungen akquiriert. Auch zwei KI-Nachwuchsgruppen beschäftigen sich mit grundlegenden Fragestellungen zu kognitiven Energiesystemen.

Zusammenfassend hat das Projekt K-ES die notwendigen Kompetenzen und Werkzeuge für die Etablierung von kognitiven Energiesystemen entwickelt, die Basis für ein Ökosystem geschaffen sowie mit den K-ES Spotlights einzelne Ansätze verständlich gemacht. Mit den Ergebnissen aus IC4CES steht ein Konzept zur Verfügung, mit dem ein Innovationscluster für die Entwicklung von kognitiven Energiesystemen aufgebaut werden kann.

Ausblick

Das Projekt Kompetenzzentrum Kognitive Energiesysteme hat mit dem Aufbau der notwendigen Kompetenzen und Werkzeuge, der Entwicklung des Ökosystems für kognitive Energiesysteme sowie der Darstellung der Potenziale über die sog. Spotlights die notwendige Basis für die erfolgreiche Etablierung von KI im Energiesystem geschaffen. Für die weitere Entwicklung liegt mit dem Konzept zum Aufbau von **IC4CES** eine Strategie vor, deren Umsetzung die konsequente Weiterführung darstellt. Drei Schwerpunkte stehen dabei im Fokus:

Idea Ecosystem

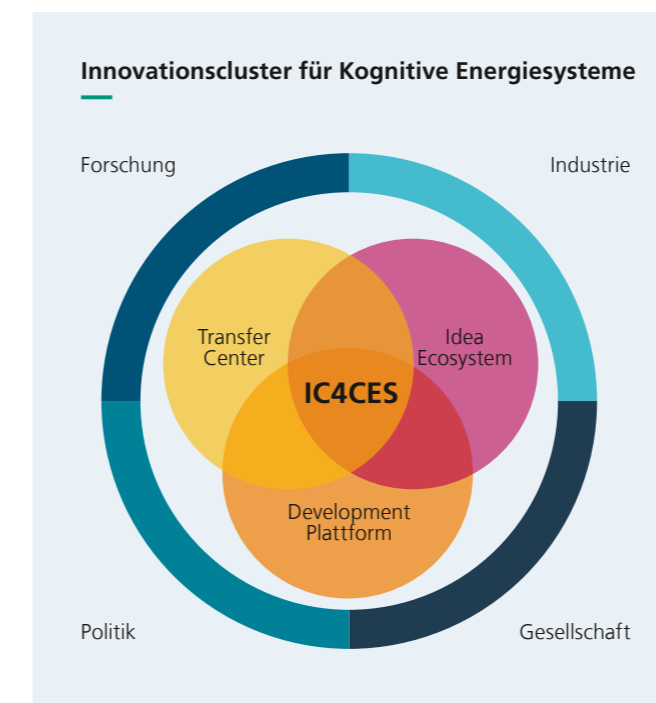
Zur langfristigen Pflege und Stärkung des Ökosystems soll ein Rahmen geschaffen werden, der die gemeinsame Entwicklung von Cognitive Energy Systems ermöglicht. Die Gründung eines IC4CES Vereins oder einer vergleichbaren Gesellschaftsform soll hierfür den organisatorischen Rahmen bilden. Weiterhin soll IC4CES als Marke etabliert werden, indem gemeinsame Forschungsprojekte für Kognitive Energiesysteme im Namen von IC4CES akquiriert und bearbeitet werden. Darüber hinaus soll eine Community-Plattform entwickelt, um den Austausch zwischen den Partnern zu stärken. Das Fraunhofer IEE bringt dabei die entwickelten Kompetenzen des K-ES ein und entwickelt diese gemeinsam mit den Partnern weiter.

Development Plattform

Für die erfolgreiche Etablierung von Kognitiven Energiesystemen ist eine leistungsfähige KI-Entwicklungsumgebung notwendig. Der Aufbau des KI-Dienstleistungszentrums für sensible und kritische Infrastrukturen KISSKI stellt hier zukünftig die notwendige Hard- und Software zur Verfügung, die speziell auf die Anforderungen Kognitiver Energiesysteme zugeschnitten ist. Das Fraunhofer IEE bringt die bereits entwickelten Werkzeuge sowie die Perspektive der Energiewirtschaft in das Projekt ein.

Transfer Center

Eine der wichtigsten Phasen im Innovationsprozess ist der Transfer in die Anwendung. Hier werden die Forschungsergebnisse verstärkt der Realität und den Bedürfnissen der Anwender ausgesetzt. Dazu soll ein Zentrum aufgebaut werden, das alle Transferpfade von Auftragsforschung und Lizenzierung über Transfer durch Köpfe und Wissenschaftskommunikation bis hin zu Ausgründungen abdeckt. Hier schlägt das Fraunhofer IEE IC4CES als Fraunhofer Leistungszentrum¹ vor. Darüber hinaus werden sich die IC4CES-Partner für den Aufbau einer »AI Testing and Experimentation Facility (TEF) for the energy sector« [EU Commission] der EU bewerben.



Das Ziel ist die Realisierung von Kognitiven Energiesystemen und die Förderung gemeinsamer Innovation, um weitere Potenziale kognitiver Energiesysteme anwendungsnah zu erschließen.

¹ <https://www.fraunhofer.de/de/institute/kooperationen/leistungszentren.html>

Kognitive Energiesysteme

Die Komplexität des Energiesystems nimmt sowohl auf der Seite der Erzeugung als auch des Verbrauchs zu, Energie soll nicht teurer werden und immer und überall zuverlässig zur Verfügung stehen. Der Einsatz von Künstlicher Intelligenz (KI) kann in dieser herausfordernden Situation helfen. Die Anwendungsfelder sind vielfältig: von der automatisierten Datenanalyse, Bild- und Tonverarbeitung über Prognosen und Entscheidungsunterstützung bis hin zu vollständig autonomen Systemen entlang der gesamten Wertschöpfungskette im Energiesystem.

Aufgrund der Vielzahl der benötigten Lösungen sind das Energiesystem und die Energiewirtschaft ideale Anwendungsfelder, um die Potenziale von KI umfassend zu erschließen und zum gesellschaftlichen Nutzen einzusetzen. Zu diesem Ergebnis kommt auch der Bundesverband der Energie- und Wasserwirtschaft (BDEW) in seiner Studie »Künstliche Intelligenz für die Energiewirtschaft« [Bremm, 2020]. Kerstin Andreae, Vorsitzende der Hauptgeschäftsführung des BDEW, fordert darin: »Lassen Sie uns gemeinsam die Energiewirtschaft zu einem Leitsektor für die Anwendung von Künstlicher Intelligenz machen!«

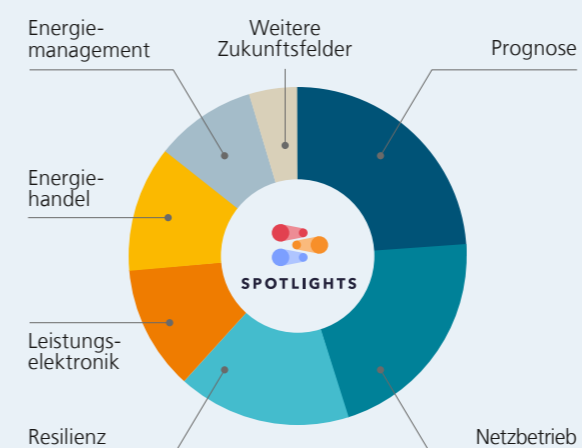
Die Einführung von KI in das Energiesystem ist eine so vielfältige Aufgabe, dass sie nur in einer offenen Innovationskultur gelingen kann. Die Entwicklung, Einführung und Umsetzung von kognitiven Energiesystemen folgt daher dem Prinzip der Open Innovation. Ein kognitives Energiesystem ist dabei ein Energiesystem, das den Zustand seiner Assets auf Basis verfügbarer Informationen selbstständig ermitteln und prognostizieren kann und durch seine Adaptionfähigkeit lernt, vorgegebene energiewirtschaftliche Ziele zu erreichen.

Anwendungsbereiche für KI im Energiesystem

Das Energiesystem muss zukünftig ein Bewusstsein über seinen eigenen Zustand entwickeln und automatisiert reagieren können. In sog. Spotlights wurde beispielhaft untersucht, welche KI-Prozesse im Energiesektor sinnvoll sind. Die Spotlights lassen sich den folgenden sieben Anwendungsfeldern des Energiesystems zuordnen:

- **Prognose:** Vorhersage von Erzeugung und Verbrauch in den Sektoren Strom Wärme und Verkehr
- **Netzbetrieb:** Zuverlässiger Netzbetrieb in einem Energiesystem mit zunehmender Unsicherheit
- **Resilienz:** Erhöhung der Widerstandsfähigkeit des Energiesystems gegenüber Fehlern und externen Eingriffen
- **Leistungselektronik:** Schnelle Entwicklung und Analyse von elektrischen Energiesystemkomponenten
- **Energiehandel:** Automatisierter Energiehandel zur besseren Vermarktung erneuerbarer Energien
- **Energiemanagement:** Intelligente Sektorenkopplung für ein besseres Zusammenspiel von Strom, Wärme und Verkehr.

Anwendungsbereiche für KI im Energiesystem



Die Ergebnisse der Spotlights werden in den folgenden Abschnitten vorgestellt. Dabei wird für jeden Anwendungsbereich ein Überblick über die durchgeführten Forschungsarbeiten, deren Anwendungsfelder im Energiesystem und abschließend ein Ausblick auf zukünftige Entwicklungen gegeben.

Weitere Informationen:
www.kognitive-energie-systeme.de



Forschung

Netzengpassmanagement unter Unsicherheiten

Für die vorausschauende Erkennung von Netzengpässen prognostizieren Netzbetreiber zukünftige Netzzustände basierend auf deterministischen Erzeugungs- und Verbrauchsprognosen. Allerdings ist es schwierig Unsicherheiten aufgrund Vorhersagefehlern oder Messungenauigkeiten einzubeziehen. Alternativ können Ensembleprognosen und probabilistische Netzberechnungen eingesetzt werden, diese sind aber sehr aufwendig und für klassische Optimierungsverfahren zur Netzengpassbehebung ungeeignet. Maschinelle Lernverfahren (ML) hingegen bieten neue vielversprechende Möglichkeiten Unsicherheiten abzubilden und die resultierenden Netzzustandsverteilungen in Optimierungsverfahren zu verwenden.

Im Spotlight-Projekt **Probabilistische Netzzustandsprognosen (NZP)** wurden zunächst mit geeigneten ML-Methoden verschiedene Verfahren zur probabilistischen NZP evaluiert. Als Eingangsdaten für die ML Modelle wurden verschiedene Variablen identifiziert und untersucht:

- Deterministische/Mittelwert-Leistungsprognosen
- Probabilistische Ensemble-Leistungsprognosen
- Probabilistische Leistungsprognosen für Verbundwahrscheinlichkeiten, basierend auf Ensemble-Prognosen

Das Projekt konzentrierte sich auf die Verwendung von Mixture Density Networks (MDNs) zur Bestimmung von probabilistischen Verteilungen der durch die verschiedenen Szenarien generierten Netzzustände. MDNs können Wahrscheinlichkeitsverteilungen der individuellen Zustände berücksichtigen und Abschätzungen bezüglich der Unsicherheiten für die betrachteten Variablen ermitteln. Hieraus können Risikoanalysen für einzelne Elemente wie Leitungen oder das Gesamtnetz erstellt werden. Auf dieser Basis lassen sich anschließend Optimierungen anwenden, um konkrete Maßnahmen für das Engpassmanagement zu ermitteln. Hierbei wurden zwei Ansätze untersucht.

Der im Spotlight **NetzLupe** untersuchte Ansatz konzentriert sich auf die Vermeidung von Netzzuständen der Zustandsverteilung, die zu kritischen Situationen führen können. Als steuernde Größe wurden hier Schalthandlungen genutzt, um möglichst keine Einspeisungen aus erneuerbaren Energieanlagen zu reduzieren. Ein selbstlernender Algorithmus wurde zum Trainieren der neuronalen Netze verwendet, der effiziente Schalthandlungen bestimmt, die die Zustandsverteilungen auf unkritische Netzzustände »fokussiert« und die Breite der Verteilung reduziert. Bei diesem Ansatz lernt der »Agent« aus vielen tausend Netzzuständen, welche Maßnahmen auch bei Abweichungen von den erwarteten Netzzuständen das Netz robust und sicher führen.

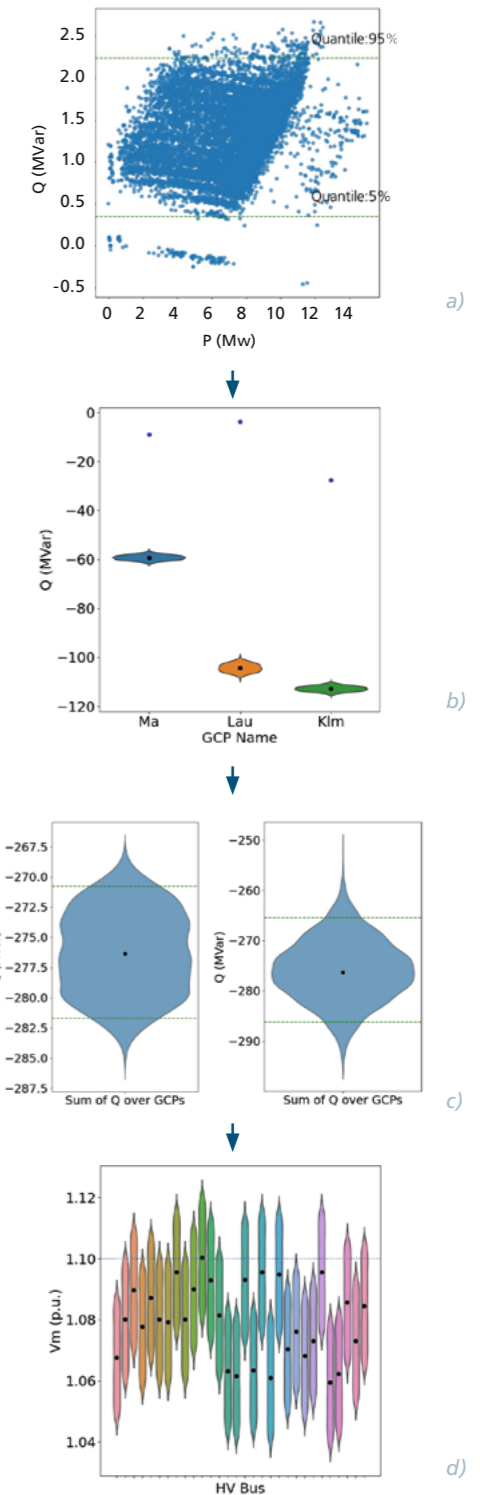


Abbildung 1: Unsicherheiten in der P-Q-Abhängigkeit an MSI HS Umspannwerken (a) führen zu Unsicherheiten beim Einstellen fester Arbeitspunkte an Netzverknüpfungspunkten zwischen HS und HÖS (b). Diese wiederum summieren sich für ganze Netzgruppen-gebiete auf und führen zu signifikanten Abweichungen der Arbeitspunkte (c) mit unterschiedlichen Unsicherheiten von 5% und 20%. Ebenfalls führen diese Unsicherheiten zu Abweichungen in den erwarteten Spannungsprofilen und können im Extremfall zu Betriebsmittelverletzungen führen (d).

- GNN4PG
- KESL2RPN
- KI-OPF
- Netzlupe
- Probabilistische Netzzustandsprognosen
- ROSALIE

Netzbetrieb

»Künstliche Intelligenz kann ein Schlüsselement bei der Identifikation und Berücksichtigung von Unsicherheiten im Netzbetrieb sein und diesen somit sicherer und zuverlässiger gestalten.«

Dr. Sebastian Wende-von Berg
Abteilungsleitung Netzbetriebsführung

In den Spotlight-Projekten **KI-OPF 1+2** wurden weitere Ansätze zur Optimierung von Netzzuständen unter Berücksichtigung von Unsicherheiten und von Blind- und Wirkleistungsstellmöglichkeiten erneuerbarer Energieanlagen untersucht. Hierbei wurde auf Grundlage von probabilistischen Netzberechnungen trainiert, wobei neben Unsicherheiten auch Netzrestriktionen wie N-1 Sicherheit berücksichtigt wurden. Dazu wurde ein kombinierter Ansatz aus überwachtem Lernen und selbstlernenden Algorithmen genutzt. Das nichtlineare Optimal Power Flow Problem wurde hierbei für das überwachte Lernen formuliert und mithilfe gradientenbasierter Optimierung gelöst. Der Agent lernt selbstständig geeignete Sollwerte für die Anlagen im Netz und kann durch die Kombination mit trainierten künstlichen neuronalen Netzen (KNN) Unsicherheiten und Netzrestriktionen berücksichtigen [Wang et al., 2022], [Wang et al., 2022 (1)].

KI-Agenten in der Netzbetriebsführung

Ein Konsortium um den französischen Übertragungsnetzbetreiber RTE hat eine Reihe von Wettbewerben ins Leben gerufen, um das Potenzial von KI-Methoden für den Netzbetrieb zu testen. Bei diesen »Learn to Run a Power Network« (L2RPN) Wettbewerben wird der Betrieb eines Übertragungsnetzes unter verschiedenen Bedingungen simuliert, einschließlich veränderlicher Einspeisungen, Lasten, Wartungsarbeiten und

bösartiger Angriffe. Das Ziel der Teilnehmer der Wettbewerbe ist die Entwicklung von KI-Agenten, die Überlastungen von Betriebsmitteln verhindern und damit Schäden und Stromausfälle vermeiden können. Die Agenten sollen lernen dynamisch Veränderungen an der Netztopologie vorzunehmen und z.B. die Stromeinspeisung anpassen (Redispatch) um dieses Ziel zu erreichen.

Im Spotlight **KESL2RPN** nahm ein Team des Fraunhofer IEE am NEURIPS 2020 L2RPN Wettbewerb teil. Der vom Team entwickelte Agent erreichte Platz 5 in einem Feld von 50 internationalen Teams. Implementiert als Expertensystem, wurden die Regeln des Agenten vorab mit Hilfe von genetischen Algorithmen optimiert. Im Spotlight **ROSALIE** wurde die Open Source Umgebung Grid2Viz, die ein Teil der Basis der L2RPN Wettbewerbe ist, um Funktionalitäten erweitert, die eine bessere visuelle Fehleranalyse von KI-Agenten im Netzbetrieb erlauben. Im Spotlight **GNN4PG** wurde eine spezialisierte Graph-Neural-Network (GNN) Architektur entwickelt, die das Stromnetz modelliert und eine geeignete Topologie für den Betrieb des Stromnetzes vorhersagt. GNNs haben den Vorteil, dass sie auf die inhärente Graphstruktur des Stromnetzes angepasst sind und korrelierte Komponenten durch die Aggregation verschiedener Knoten modellieren können.

Anwendung

Die von Netzbetreibern am häufigsten eingesetzten Prognosen zur Vorhersage von Erzeugung und Verbrauch sind Erwartungswertprognosen ohne Informationen über deren Unsicherheiten. Die Netzbetreiber können das Risiko für Prognosefehler im Voraus schwer abschätzen und es kann zu Problemen im Netzbetrieb führen, wenn sich die Erzeugungs- und Lastsituation anders einstellt als erwartet.

Bei den Einspeiseprognosen sind im Wesentlichen Unsicherheiten in den Wettervorhersagen dafür verantwortlich, dass es zu unerwarteten Situationen im Netzbetrieb kommt. Bei den Last- bzw. Verbrauchsprognosen kommen zu den Unsicherheiten durch Verbraucher nicht bekannte Regelungen von Anlagen in Mittel- und Niederspannungsnetzen sowie Industrieanlagen hinzu. Netzbetreiber müssen also Sicherheitsmargen in ihre Maßnahmen einbeziehen. Tendenziell können Netzkapazitäten nicht voll ausgenutzt werden und mehr erneuerbare Energie als nötig bleibt ungenutzt. Das kostet zusätzlich Geld und erhöht den CO₂ Ausstoß.

Die untersuchten Ansätze der probabilistischen Netzzustandschätzung und Optimierung mithilfe künstlicher Intelligenz können zu einem effizienteren und sichereren Netzbetrieb führen, weil die Unsicherheiten besser eingeschätzt und Maßnahmen genauer dimensioniert werden können. Damit diese Unsicherheiten abgebildet und berücksichtigt werden können, sind grundlegend große Mengen an (probabilistischen) Netzberechnungen und deren Auswertung nötig. Dies ist aufwendig und kostet Rechenzeit und -leistung. KNN sind in der Lage, diese große Menge an Daten in Echtzeit zu verarbeiten und instantan passende Ergebnisse zu generieren. Das macht eine Berücksichtigung von Unsicherheiten im operativen Netzbetrieb möglich.

Ausblick

Erste Anwendungen dieser Methoden werden aktuell in Forschungsprojekten Redispatch 3.0 und Spannend der OptiNet-Programme untersucht. Im Rahmen der ACER-Verordnung werden probabilistische Netzberechnungen zukünftig vorgeschrieben sein [ACER, 2019].

Die hier entwickelten Ansätze und Methoden werden im Laufe der Jahre 2023 und 2024 in den genannten Projekten weiterentwickelt und innerhalb prototypischer Pilotprojekte angewendet. Insbesondere im Mittel- und Niederspannungsbereich werden neuartige Methoden für die Schätzung und Optimierung der Netzbetriebsführungen benötigt, da eine vollständige Messabdeckung fehlt und diese sowie Unsicherheiten von Erzeugungs- und Verbrauchsprognosen berücksichtigt werden müssen. Die Nutzung der künstlichen Intelligenz kann hier der Schlüssel sein, um z.B. die große Anzahl an erwarteten Elektroautos und Wärmepumpen sowie weiterer flexibler Erzeuger und Verbraucher sicher und nachhaltig in die Netze zu integrieren und diese für die Netzsicherheit und -stabilität zu nutzen.

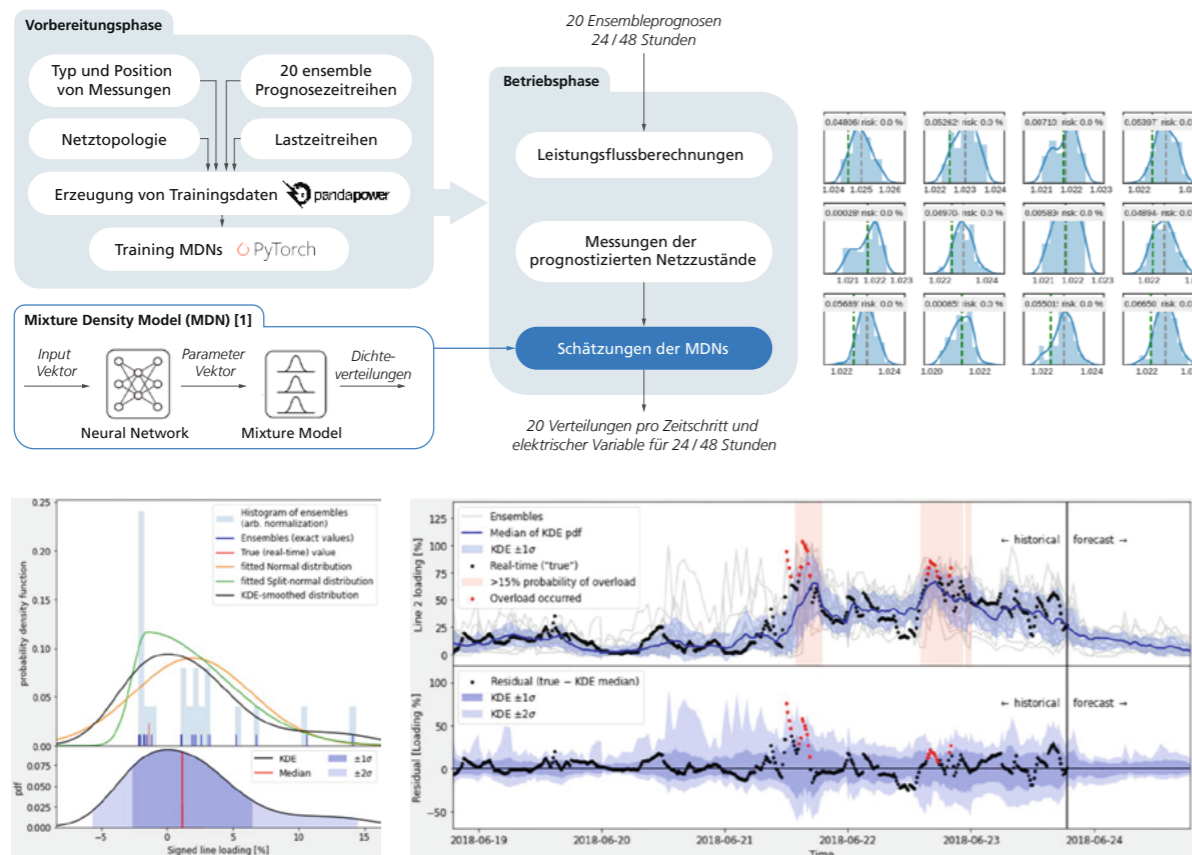


Abbildung 2: Der Weg von Ensembleprognosen über die Verarbeitung mit MDNs (obere Reihe) oder Glättungsfunktionen (untere Reihe) hin zu Netzzustandsverteilungen.

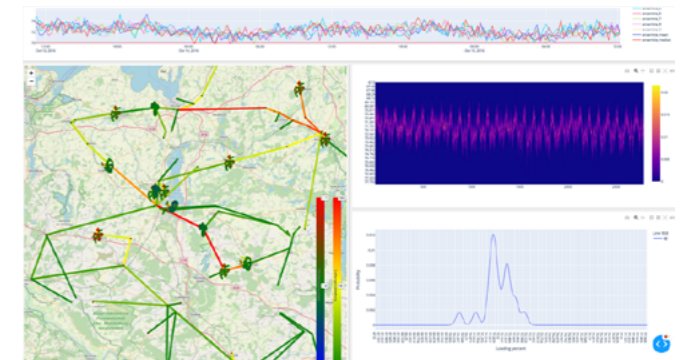


Abbildung 3: Darstellung der Netzzustandsverteilungen anhand einer interaktiven Netz Karte.



Prognosen

»KI ermöglicht fundierte Entscheidungen durch bessere und anwendungsspezifische Vorhersagen.«

Dr. Malte Siefert

Gruppenleitung Prognosen für Energiesysteme
Abteilung Energiemeteorologie und Geoinformationssysteme

Forschung

Aufgrund der zunehmenden Dynamik von Erzeugung und Verbrauch gewinnen datengetriebene Prognoseverfahren auf Basis maschinellen Lernens zunehmend an Bedeutung, um die Planbarkeit und Koordination aller Prozesse im Energieversorgungssystem weiterhin zu gewährleisten. Neben der Entwicklung neuartiger Prognosen beschäftigt sich die aktuelle Forschung und Entwicklung mit der Verbesserung der Vorhersagequalität. Dabei spielen zusätzliche Eingangsgrößen wie Satelliten- und GIS-Daten eine Rolle, aber auch der Einsatz neuer Verfahren des maschinellen Lernens. Große Fortschritte bei den maschinellen Lernverfahren ergeben sich auch durch

Methoden, die bereits auf Basis weniger Daten eine sehr hohe Güte erreichen und von bereits gelernten Problemen auf neue Probleme verallgemeinern können.

Durch die Zunahme der Prognoseunsicherheiten aufgrund des größeren Einflusses des Wetters und der Wechselwirkungen in der Stromerzeugung werden die klassischen deterministischen Prognosen in einigen Jahren durch probabilistische Prognosen abgelöst, die neue Verfahren zur robusten Entscheidungsfindung bei den Netzbetreibern erfordern.

Anwendung

Durch die Digitalisierung und den Rollout intelligenter Messsysteme stehen zunehmend Verbrauchszeitreihen mit mindestens viertelstündlicher Auflösung zur Verfügung, die datengetriebene Ansätze zur Prognose des individuellen Verbrauchs ermöglichen.

Im Forschungsschwerpunkt »Data4Grid-Challenge – KI-gestützte Verbrauchsprognosen auf Basis von Smart-Meter-Daten« wurden Lösungen für genau diesen Anwendungsfall gesucht. Für die vorliegenden Verbrauchszeitreihen wurden insbesondere die Tageszeit, Kalenderinformationen (Wochentag, Feiertag, etc.) sowie historische Messwerte als die Faktoren mit dem größten Einfluss auf die Verbrauchsprognose identifiziert. Mit Hilfe des Multi-Tasking-Lernens konnte insbesondere für Portfolios mit einer größeren Anzahl von Verbrauchern eine hohe Prognosegüte erreicht werden (Abbildung 4).

Darüber hinaus beschäftigten sich die Projekte **Mobicast** und **EV Forecast** mit dem Stromverbrauch beim Laden von Elektrofahrzeugen. Während in Mobicast die Ladeleistung an Ladestationen mit Hilfe von Transformatoren prognostiziert wurde, befasst sich EV Forecast mit der Prognose geografisch abgegrenzter Ladeleistung einer Elektrofahrzeugflotte unter Berücksichtigung räumlicher Zusammenhänge.

In **Heatcast** wurden Prognosen für den Wärme- bzw. Kältebedarf eines Produktionswerkes erstellt. Mit Hilfe dieser Prognosen sollte der Eigenverbrauch erneuerbarer Energien durch den Einsatz von nichtelektrischen Energiespeichern maximiert werden.

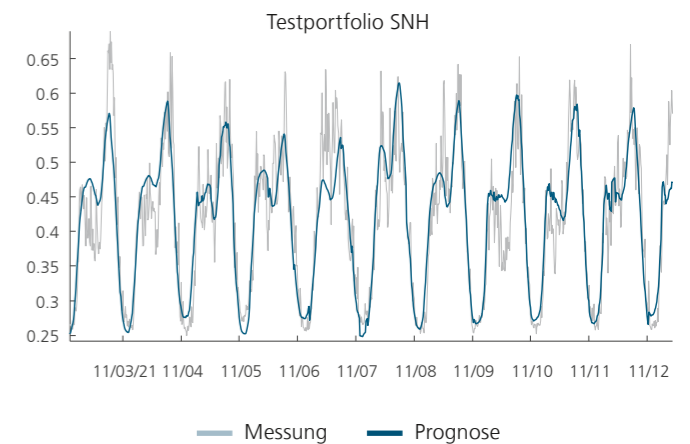


Abbildung 4: RMSE-optimierte Prognose für ein Portfolio aus mehreren Verbrauchern basierend auf Multi-Task-Learning.

Für die Prognosen wurden ebenfalls Temporal Fusion Transformer eingesetzt, die in der Lage sind, verschiedene Zeithorizonte auch unter Berücksichtigung von Wahrscheinlichkeiten zu prognostizieren.

Die Prognose von Leistungsflüssen im elektrischen Netz ermöglicht es Netzbetreibern, vorausschauende Netzberechnungen durchzuführen und somit Engpässe frühzeitig zu erkennen und Gegenmaßnahmen zu ergreifen.

Im Projekt **Vertikale Lastprognose** wurde ein Paper [Brauns et al., 2022] erstellt, das die Prognose von vertikalen Leistungsflüssen bzw. Lasten mit Hilfe von Long-Short-Term-Memory-Modellen beschreibt.

Im Projekt **PowerGraph** wurden vertikale Leistungsflüsse an Transformatoren zwischen Hoch- und Höchstspannung mit Hilfe eines Graph Neural Network (GNN) prognostiziert. Das GNN wurde eingesetzt, um mehrere Eingangsgrößen (Wetterprognosen, Verbrauchsprognosen, Kalenderdaten etc.) pro Knoten (Transformatoren) unter Berücksichtigung von Kanteninformationen auf die Zielgrößen – die vertikalen Leistungsflüsse – abzubilden. Da an verschiedenen Transformatoren je nach lokal vorhandenen Energieträgern und Verbrauchern ein unterschiedliches Zeitreihenverhalten auftritt, ein GNN aber typischerweise für alle Knoten die gleiche Prognosefunktion lernt, wurde ein Bayesian Embedding Multi-Task Learning Ansatz in das GNN integriert (BEMTL). Dieser erlaubt es dem Modell, zwischen einzelnen Transformatoren zu unterscheiden und diese bei der Prognose entsprechend zu berücksichtigen. Globale Abhängigkeiten zwischen den Leistungsflüssen an verschiedenen Transformatoren ergeben sich vor allem durch die Auswirkungen von Schaltzustandsänderungen, Zu- oder

Rückbau von Netzelementen oder Wartungsarbeiten an einzelnen Elementen. Das verbesserte Prognoseverhalten zeigt sich in den Beispielzeitreihen für zwei Transformatoren in Abbildung 5.

Die temporäre Inaktivität eines Transformators hat jeweils Auswirkungen auf den Leistungsfluss des anderen Transformators. Das BEMTL-GNN ist gegenüber dem BEMTL in der Lage, dieses Verhalten in der Prognose zu berücksichtigen. Eine Erweiterung des Verfahrens auf stärker vernetzte Graphen unter Einbeziehung weiterer Netzelemente kann perspektivisch dazu dienen, komplexe Zusammenhänge zwischen Systemkomponenten des elektrischen Netzes zu erlernen und in Prognosen zu berücksichtigen.

Aktuelle Forschungsarbeiten zielen darauf ab, die etablierte Vorhersagequalität zu verbessern. Dies geschieht z.B. durch neue Verfahren wie **Temporal Fusion Transformers (TFTs)** [Lim et al., 2021], die es ermöglichen, ein einziges Modell nicht nur für einen Standort, sondern für mehrere Standorte gleichzeitig zu trainieren (Multitask-Learning). Auf diese Weise können gelerntes Verhalten an anderen Standorten sowie räumliche und zeitliche Abhängigkeiten in die Prognose einfließen und diese verbessern.




Abbildung 5: Normierte Folgetagsprognosen des entwickelten Modells BEMTL-GNN (unten) und des Benchmarkmodells BEMTL (Mitte) an zwei Transformatoren eines Umspannwerks.

Der Vorteil von TFTs ist, dass sie nicht nur eine deterministische Prognose erzeugen, sondern auch Aussagen über die Wahrscheinlichkeitsverteilung der zukünftig erzeugten Leistung erlauben.

Satellitendaten spielen eine immer wichtigere Rolle für die Vorhersage der Erzeugung durch Photovoltaik. Optical Flows werden bereits für zukünftige Wolkenbewegungen verwendet, können aber nicht die Wolkenbildung und -auflösung

berücksichtigen oder Informationen aus mehreren Bildkanälen integrieren. Im Projekt **NeuraSat** wird KI zur Verbesserung der Strahlungsprognose eingesetzt. Das Modell besteht aus CNN und Max-Pooling-Schichten im räumlichen Encoder, 3D-CNN und Optical-Flow-Vorhersagen im zeitlichen Encoder und Axial Attention im räumlichen Aggregator. Diese Kombination mit mehreren Satellitenkanälen und GIS-Daten lernt die räumlichen und zeitlichen Zusammenhänge und konnte eine verbesserte Vorhersage gegenüber Wolkenvektoren zeigen.

Ausblick

In Zukunft wird die Komplexität des Energiesystems durch die Integration neuer Erzeuger, Verbraucher und Speicher sowie durch die Vernetzung der Sektoren untereinander deutlich zunehmen.

Ein resilienter Betrieb wird nur durch eine starke Koordination der zahlreichen Komponenten gelingen, die dazu umfangreiche Daten austauschen müssen. Eine vorausschauende Planung auf Basis von Prognosen ist dabei entscheidend, um den Betrieb der Komponenten optimal aufeinander abstimmen zu können. Hierfür werden automatisierte, datenbasierte Prognoseverfahren benötigt, die in der Lage sind, mit den großen Datenmengen umzugehen und die vielfältigen Einflüsse zu berücksichtigen.

Ein weiterer Forschungsschwerpunkt ist die Berücksichtigung des Datenschutzes und der Informationssicherheit. Hier helfen Methoden des vertraulichen Lernens (confidential learning), um die Daten absolut vertraulich zu verwenden und dennoch die Vorteile datengetriebener Verfahren nutzen zu können. Die Prognosezeiträume werden einerseits sehr kurze Zeiträume im Minutenbereich und andererseits sehr lange Zeiträume bis hin zu Jahren umfassen.

Die zukünftigen Herausforderungen beziehen sich auf folgende Aspekte:

- Automatisierte, robuste und skalierbare Verfahren für viele zehntausend Prognosen (MLOps).
- Adaptive Verfahren, die neue Systemeigenschaften sofort berücksichtigen und sich selbstständig anpassen (Continual Learning).
- Verfahren, welche die Wechselwirkungen zwischen den Komponenten berücksichtigen wie z.B. deutlich weiterentwickelte Graph Neural Networks.
- Probabilistische Verfahren, die auch die Unsicherheiten von Prognosen vorhersagen und die Berücksichtigung von Risiken ermöglichen.
- Verfahren, die anwendungsspezifisch auch die Optimierung von Systemen mit der Prognose verknüpfen („Prescriptive Analytics“), also die Vorhersage mit dem Energiemanagement verbinden.

Forschung

Die Anforderungen an das zukünftige Energiesystem wachsen von Tag zu Tag. Die Belastungen und Risiken für einen sicheren Betrieb steigen dabei nicht nur im Bereich der elektrischen Stromversorgung, sondern auch in anderen kritischen Infrastrukturen. Umso wichtiger ist es diese Systeme zukünftig resilient zu gestalten und mit geeigneten Hilfsmitteln und Methoden verstärkt auf die Anforderungen von morgen zu reagieren. In diesem Abschnitt werden verschiedene Lösungsansätze präsentiert, um Teile unserer kritischen Infrastruktur zu stärken.

Zur resilienten Stärkung eines Systems gibt es viele verschiedene Ansätze und Möglichkeiten. In der Resilienzforschung ist der Resilienzzyklus eine weit verbreitete Methode, um das Durchlaufen einer Belastung zu beschreiben. Dabei wird zwischen fünf verschiedenen Phasen unterschieden [Häring, 2021].



Durch den vermehrten Einsatz von KI im Energiesystem nimmt die Komplexität des Gesamtsystems rapide zu. So bestehen KI-Infrastrukturen meist aus hochkomplexen Black-Box-Modellen und umfangreichen Datenpipelines. Bedingt durch die hohe Komplexität werden einzelne Handlungen und Prozesse jedoch immer undurchsichtiger und schwerer nachvollziehbar. Dies macht die Systeme immer schwieriger zu überwachen und öffnet neue Wege für Angriffe auf das Energiesystem. Eine unzureichende Robustheit und Resilienz der KI-Infrastrukturen gegenüber Angriffen kann zu hohen wirtschaftlichen Verlusten und zur Destabilisierung des Energiesystems führen. Vertrauenswürdige KI, welche robust, angriffssicher und hinreichend transparent ist, stellt daher einen essenziellen Baustein für die Sicherheit des zukünftigen Energiesystems dar.

Im Rahmen der kognitiven Energiesysteme wurden Forschungen, welche auf einige dieser Phasen abzielen, betrieben, wobei immer der Einsatz von Methoden aus dem Bereich der künstlichen Intelligenz bzw. des maschinellen Lernens im Vordergrund stand. Dieser Trend zeigt sich nicht nur in der Forschung, sondern hat auch bereits in der Anwendung einen hohen Stellenwert eingenommen.

Auch zeigen erste Absichten der Europäischen Union zur stärkeren Regulierung von KI in kritischen Infrastrukturen, dass der Bedarf an vertrauenswürdiger KI auch auf politischer Ebene gesehen und vorangetrieben wird. Die Europäische Kommission veröffentlichte am 21.04.2021 mit dem sogenannten »Artificial Intelligence Act« einen Entwurf zur Festlegung harmonisierter Vorschriften für künstliche Intelligenz [Commission, E., 2021].

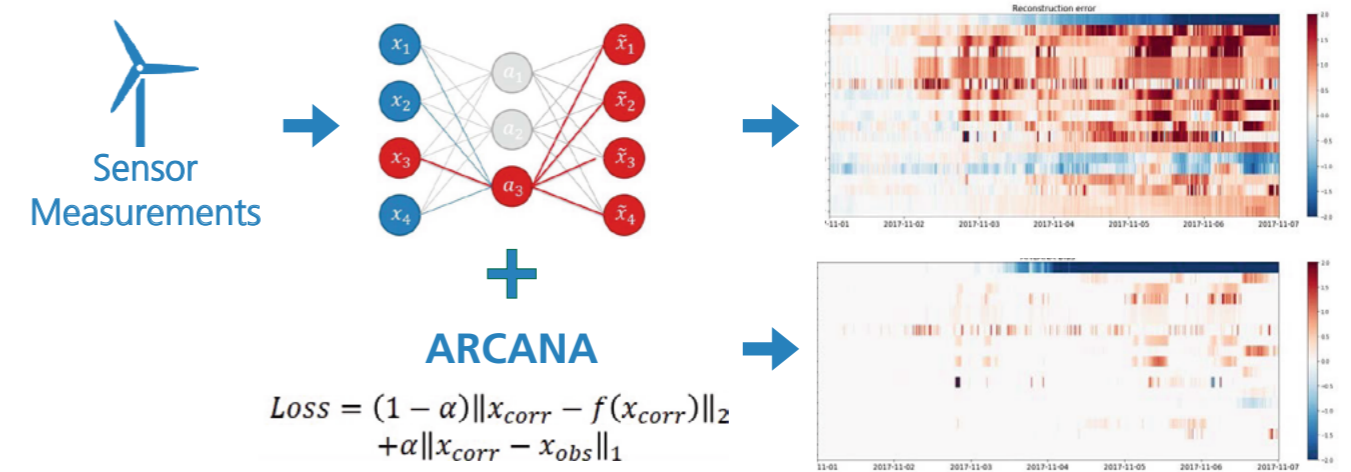


Abbildung 6: Visualisierung des ARCANA Ansatzes.

- AAE 
- ARCANA 
- CIA 
- GANs4RE
GANs4RE v2 
- TEXES 
- TLP4Heat 

Resilienz

»Resilienz ist die Fähigkeit eines Systems, seine Funktionsfähigkeit unter Belastungen aufrechtzuerhalten beziehungsweise kurzfristig wiederherzustellen und daraus gestärkt hervorzugehen«

Florian Rehwald
Abteilung Energieinformatik und Informationssysteme

Nach dem »Artificial Intelligence Act« sollen insbesondere risiko-reiche KI-Systeme, welche in kritischen Infrastrukturen wie dem Energiesystem eingesetzt werden, strengeren Regelungen unterlegt werden. Verbindliche Regeln sollen mitunter eine erhöhte Sicherheit, Vertrauenswürdigkeit und Transparenz risikoreicher KI-Systeme schaffen. Die Bundesnetzagentur hat diesen Vorschlag der Europäischen Union grundlegend befürwortet, zeigt in ihrem Bericht jedoch auf, dass an bestimmten Stellen weiterer Handlungsbedarf besteht [Bundesnetzagentur, 2021].

Mehrere Spotlight-Projekte fokussierten daher darauf, die Transparenz und Robustheit von Systemen zu steigern. Zur Erhöhung der Transparenz wurden Methoden aus dem Bereich der Explainable AI und zur Steigerung der Robustheit von KI-basierten Anwendungen gegenüber Adversarial Attacks untersucht.

Aus einem dieser Spotlights ist der sogenannte »ARCANA« Algorithmus entstanden [Roelofs et al., 2021]. Dieser kann die durch einen Autoencoder-basierten Anomalieerkennungsalgorithmus entdeckten Anomalien auf ihre Ursache hin interpretierbar machen.

Hierfür wird der Rekonstruktionsfehler für alle Eingangsgrößen des Autoencoder-Modells benutzt, um die mit einer Anomalie am stärksten korrespondierenden Eingangsgröße hervorzuheben. Abbildung 6 stellt die Methodik am Beispiel von Windenergie-daten dar [Roelofs et al., 2021].

Neben der ARCANA-Methode wurde im Spotlight-Projekt **CIA** die TCAV-Methode (Testing with Concept Activation Vectors) als weiteren Ansatz zur Steigerung der Transparenz von KI-Anwendungen untersucht [Kim, 2018]. Dieser ermöglicht eine Überprüfung, ob ein ML-basierter Klassifizierungsalgorithmus bestimmte Konzepte erlernt hat. Auch hierbei wurde der Use Case der Anomalieerkennung in Windenergieanlagen betrachtet. Während in ARCANA der Fokus auf der Einordnung verschiedener Anomalien liegt, stellte sich in CIA heraus, dass die Überprüfung von Konzepten für unüberwachte Verfahren nur bedingt möglich ist. Daher wurde in diesem Projekt das Normalverhalten von Windenergieanlagen in den Vordergrund gerückt [Kim, 2018].

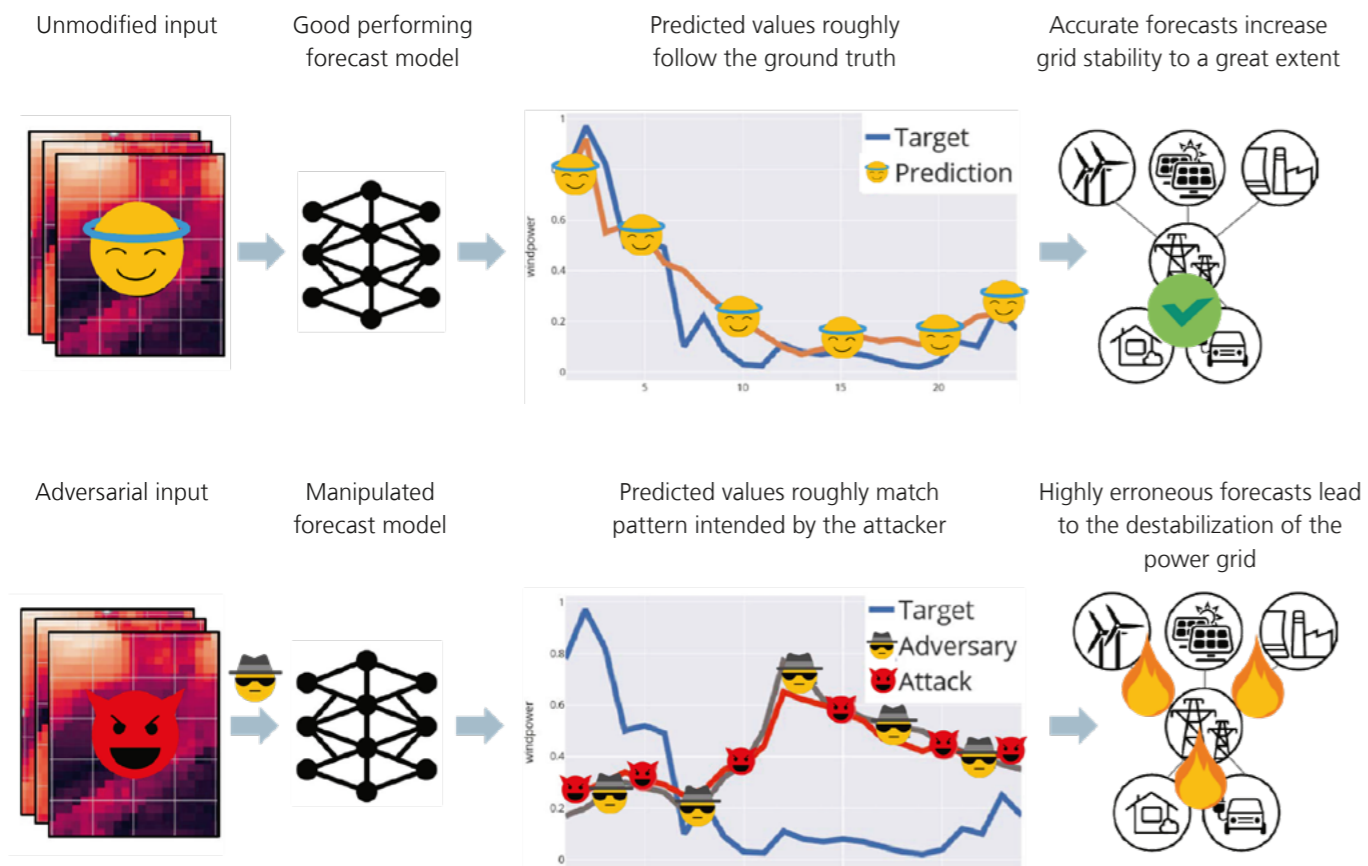


Abbildung 7: Illustration von Adversarial Attacks auf Windleistungsprognosemodelle.

Anwendung

KI-Methoden finden in immer mehr Anwendungen im Energiesektor Einzug – wie z.B. bei Windleistungsprognosen.

Im Projekt »Adversarial Attacks im Energiesektor« (**AAE**) wurde die Robustheit KI-basierter Windleistungsprognosemodelle gegenüber vorsätzlich – aber unmerklich – veränderten Eingangsdaten, welche auf eine gezielte Verfälschung der Modellvorhersagen abzielen, untersucht. Verschiedene Analysen zeigen auf, dass insbesondere Modelle mit hochdimensionalen Eingangsdaten (wie z.B. Wetterkarten) sehr anfällig gegenüber dieser Art von Adversarial Attacks sind. So konnten die Prognosen solcher Modelle bereits durch leichte Veränderungen der Eingangsdaten nahezu beliebig manipuliert werden. Einen weiteren Untersuchungsaspekt stellt das Adversarial Training dar. Das ist eine Methode, um die Robustheit von KI-Verfahren gegenüber Manipulationen der Eingangsdaten zu erhöhen, indem neben den unveränderten Eingangsdaten auch manipulierte Daten in den Trainingsprozess miteinbezogen werden. Als Ergebnis dieser Untersuchungen konnte festgehalten werden, dass die Robustheit der Prognosemodelle mithilfe von Adversarial Training exorbitant gesteigert werden kann und diese Steigerung lediglich mit einer geringen Verschlechterung der Prognosegüte einhergeht. Zusammenfassend zeigte AAE, dass KI-basierte Prognosemodelle, welche hochdimensionale Eingangsdaten aus sicherheitskritischen Schnittstellen beziehen, vor der Operationalisierung stets hinsichtlich ihrer Anfälligkeit gegenüber Adversarial Attacks geprüft und ggf. entsprechende Methoden (wie z.B. Adversarial Training) angewendet werden sollten, um die Modelle vor solchen Angriffen zu schützen.

Eine weitere Hürde bei der Anwendung von KI-Methoden im Energiesektor stellt die oftmals mangelhafte Datenverfügbarkeit dar. Die Projekte **GANs4RE** und **TLP4Heat** adressieren genau diese Herausforderung. Ziel dieser Spotlights war es, die Datengrundlage für verschiedene KI-Anwendungen zu verbessern

Ausblick

Die Projekte zeigen Ansätze zur Steigerung der Resilienz des Energiesystems. Gefahren und potenzielle Risiken wachsen jedoch und machen weitere Forschungsergebnisse für die Gestaltung eines robusten und resilienten Energiesystem unabdingbar. Hierfür bestehen noch viele Potentiale in allen Phasen

bzw. überhaupt erst zu schaffen und damit einen weiteren wichtigen Baustein für Resilienz-stärkende Methoden in der Anwendung zu liefern.

Ein bedeutender Aspekt für den Betrieb resilienter Systeme wird durch den Resilienzyklus nicht beleuchtet. Dieser besteht darin, dass ein resilientes System aus einer durchlaufenen Belastung gestärkt hervorgehen sollte. Ein Beispiel hierfür ist das kontinuierliche Lernen im Kontext der künstlichen Intelligenz – auch oft mit active learning verbunden. Für den Fall der Anomalieerkennung benötigt es hierfür jedoch genaue Informationen, insbesondere ob es sich um falsch oder richtig erkannte Anomalien handelt. In der Realität ist die Überprüfung von erkannten Anomalien jedoch mit einem hohen Zeit- und Ressourcenaufwand verbunden und erfordert die Einbeziehung von Instandhaltungsinformationen sowie domänenspezifischem Expertenwissen.

Im Projekt TLP4Heat wurde für die Domäne der Fernwärmesysteme ein Ansatz für die Nutzbarmachung der Instandhaltungsinformationen und somit eine Grundlage für eine kontinuierliche Verbesserung von Anomalieerkennungsmethoden entwickelt.

Ein weiteres häufig auftretendes Problem bei der Nutzung von KI-Methoden ist eine zu geringe Datenmenge. In GANs4RE wurden daher mit Hilfe von Generative Adversarial Networks (GANs) Zeitreihendaten von erneuerbaren Energieanlagen (insbesondere von Windenergieanlagen) erzeugt. Für den Fall der Anomalieerkennung wurde ein Ansatz mit einem Conditional Generative Adversarial Network (CGAN) untersucht. Dieser ermöglicht es, durch die Vorgabe einer bestimmten Bedingung verschiedene Zeitreihentypen zu erzeugen.

In dem betrachteten Use Case wurde als Bedingung die vorherrschende Windgeschwindigkeit, der Standort sowie der Verhaltenstyp (normal oder anormal) vorgegeben.

des Resilienzyklus. Eine gute Orientierung für zukünftige KI-Anwendungen liefert das Projekt **TEXES**, in dem sowohl die kritischsten Bestandteile einer KI-Anwendung aufgezeigt als auch Gegenmaßnahmen zur Resilienzsteigerung erläutert werden.

- Aidentify 
- Alsland 
- CTRL 
- InvEx 
- SmartTE 

Leistungselektronik

»Die Integration von KI in die Leistungselektronik wird eine entscheidende Rolle bei der Verbesserung der Energieeffizienz und Zuverlässigkeit spielen und ist ein Muss angesichts des aktuellen Fachkräftemangels«

Dr. Ron Brandl

Gruppenleitung Leistungselektronische Applikationen
Abteilung Stromrichtertechnik und elektrische Antriebssysteme

Die Designautomatisierung wird für die Leistungselektronik sowie die Verbesserung der Regelung von Stromrichtersystemen und elektrischen Maschinen immer wichtiger, um höhere Wirkungsgrade, kompaktere Designs und komplexere Regelungen zu niedrigsten Kosten zu erreichen. Die größten Herausforderungen beim Entwurf und der Regelung von Leistungselektronik, insbesondere bei hochintegrierten Systemen, sind die Wechselwirkungen zwischen verschiedenen physikalischen Komponenten, die Verkürzung der Entwurfszeit und die Optimierung mit mehreren Parametern und mehreren Zielen. Techniken für die Auslegung und Regelung von Leistungselektronik können dabei helfen, leistungselektronische Systeme in Bezug auf Wirkungsgrad, Größe, thermische und elektrische Leistung und Kosten zu optimieren und die durch die derzeit verfügbaren Technologien auferlegten Designgrenzen zu erkennen und zu verstehen.

Forschung

Die Anwendung von Methoden der künstlichen Intelligenz in den Bereichen Leistungselektronik, Stromrichtertechnik und elektrische Maschinen auf Komponentenebene (wie z.B. Design und Auslegung), sowie die regelungstechnische Anwendung sind derzeit noch wenig verbreitet im Vergleich zu anderen Fragestellungen und Bereichen im Energiesystem. Doch gerade aufgrund der aktuellen und kommenden Bedeutung der Leistungselektronik in allen Bereichen der Energietechnik nimmt die Anwendung von Methoden der KI vor allem in der Auslegung, Regelung und Instandhaltung von leistungselektronischen Komponenten und Systemen Einzug.

Aktuelle Untersuchungen der Anwendung zeigen, dass insbesondere Methoden des maschinellen Lernens für Revisionsansätze zur Erweiterung von Regelungen stark im Kommen sind. Neben der Auslegung von Komponenten von leistungselektronischen Systemen sieht die Community vor allem den Einsatz von metaheuristischen Methoden und maschinellem Lernen in der Regelungstechnik als vorteilhaft an (siehe Abbildung 8).

Neben der Einführung von Methoden der KI in der Leistungselektronik sind jedoch noch wichtige Fragen zu ihrer Etablierung ungelöst, die notwendig sind, um den Einsatz in der Industrie und im Feld auszubauen:

- Dynamische Performance und Konvergenzgeschwindigkeit
- Robustheit und Allgemeingültigkeit in der Anwendung
- Nachvollziehbarkeit / Interpretierbarkeit
- Rechenperformance und Genauigkeit
- Normative Validierung

Es ist die Aufgabe der Forschung, neben dem allgemeinen Einsatz von KI zur Optimierung über die gesamte Wertschöpfungskette hinweg, diese Fragen zu beantworten, da sonst eine Anwendung in der Industrie und eine Standardisierung in solch kritischen Systemen nicht erreicht werden kann.

Anforderung der KI im Lebenszyklus der LE

Anforderung	Design (heatsink)	Regelung (Smart CTRL)	Instandhaltung (RUL)
Rechenaufwand	•••	••	••
Geschwindigkeit	•	•••	••
Genauigkeit	••	•••	•••
Datensatz	•	•	•••
Interpretierbarkeit	•	•••	•••

••• Hoch •• Mittel • Niedrig

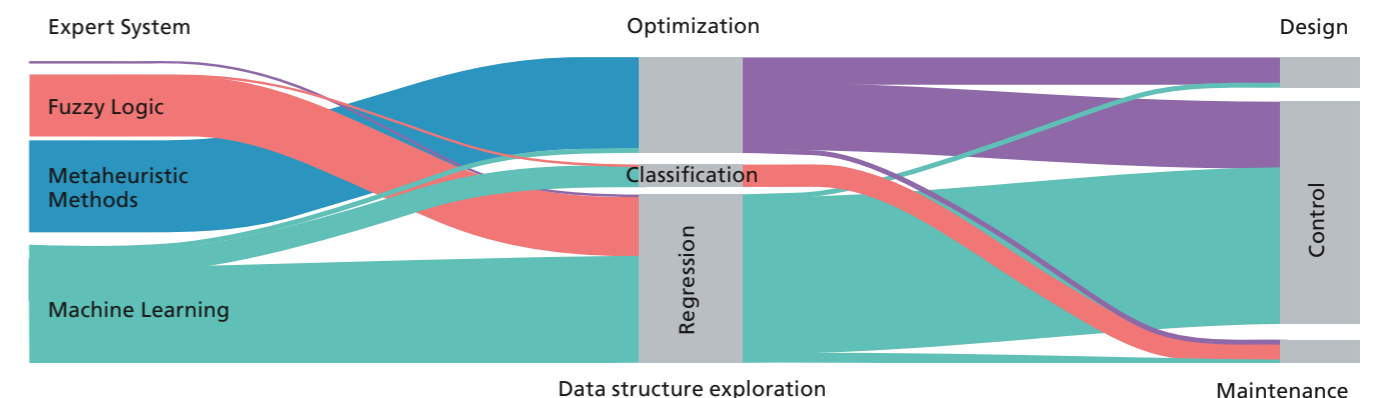


Abbildung 8: Sankey Diagramm – KI Methoden | Fkt | Anwendung in der Leistungselektronik [Zhao et al., 2021].

Anwendung

Das K-ES hat sich zur Aufgabe gemacht, die Anwendung der verschiedenen Einsatzgebiete von KI-Lösungen in der Leistungselektronik zu erörtern und die genannten Fragestellungen wissenschaftlich zu diskutieren.

Aufgrund des anhaltenden Mangels an Fachkräften für die Entwicklung von Leistungselektronik und Stromrichter-Systemen für PV, Wind, Batterie und Wasserstoff wurde im Spotlight **InvEx** mit der Entwicklung eines Tools für die Entwicklung von Stromrichtern begonnen.

Der Weg zur Entwicklung von Stromrichtern ist lang, kompliziert und erfordert Schnittstellen zwischen verschiedenen Experten. Aufgrund des großen Anwendungsbereichs von Stromrichter-Systemen im Alltag zeigt das Projekt jedoch ein breiteres Potenzial mit internationaler Nachfrage. Insbesondere bei der thermischen Auslegung von Bauteilen konnte ein Verfahren entwickelt werden, das die zeitaufwendige und rechenintensive Simulation um ein Vielfaches (1:2500) verkürzen kann.

Der Ansatz zu einem allgemeingültigen Expertentool zur Auslegung von einem Stromrichter-System bedingt allerdings die gemeinschaftliche Arbeit von Forschung, Industrie und Normung.

Die K-ES Spotlights **Alsand** und **Aldentify** haben es sich zur Aufgabe gemacht, mit supervised learning Methoden des Machine Learning einen regelungsoptimierten Ansatz zur Erkennung verschiedener Netzparameter und Netzphänomene in eine bestehende Stromrichter-Regelung eines netzbildenden Batteriespeichersystems zu integrieren.




Abbildung 10: Analyse der falsch vorhergesagten Werte unter Verwendung von LSTM zur Erkennung von Inselbildungen für 1640 zufällig initialisierte Simulationen mit einer Gesamtgröße des Datensatzes von 103.377.400 Zeitwerten. Dynamische Systemereignisse bei $t = 0,85$ s (e.g. Lastschaltung, Frequenzvariation, ...), Inselbildung bei $t = 1,3$ s (Schließen des PCC-Schalters).

Weiter bedingen aktuelle Verfahren teilweise aktive Methoden zur Netzerkennung, was die Netzqualität stark beeinflussen kann. Ziel der Projekte war eine minimalinvasive Erkennungsmethode mit vertretbarem Berechnungsaufwand zu entwickeln um sie auf aktuellen Stromrichter-Technologien einsetzbar zu machen.

Mit den auf Basis wissenschaftlich anerkannter Netzdaten entwickelten Alsand Erkennungsmodellen (LSTMs und XGBoost) konnten Wahrscheinlichkeitsaussagen (>99%) für die Erkennung von Inselnetzbildungen durch einen Messpunkt in stark stromrichterdominierten Netzen getroffen werden. Abbildung 10 erläutert die Analyse der resultierenden Vorhersagen möglicher Inselnetzbildungen.

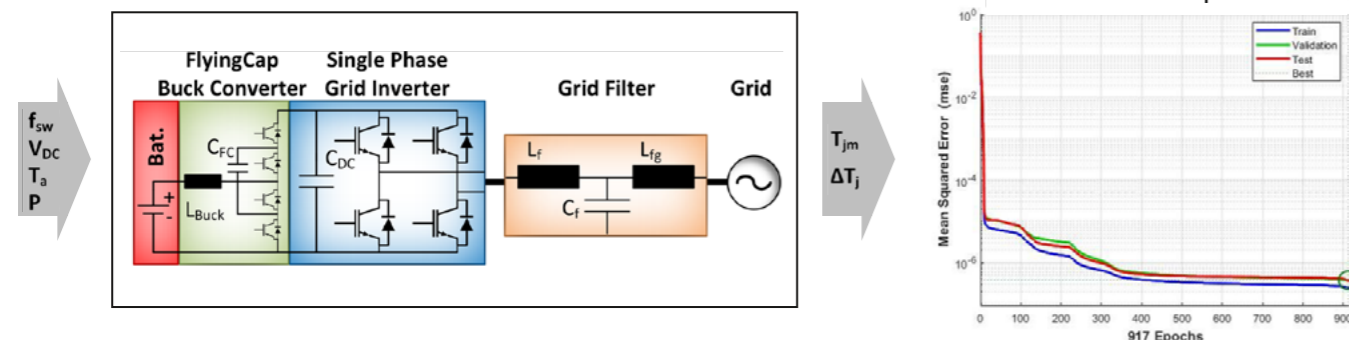


Abbildung 9: Einphasiges Batteriestromrichter-Simulationsmodell mit Eingangs- und Ausgangsdaten sowie die Trainingsergebnisse der Darstellung als neuronales Netz.

Das Spotlight-Projekt **Aldentify** entwickelt eine Methode für online supervised learning Training auf der Grundlage von Netzsimulationen zur Erkennung der Netzimpedanz bei netzbildenden Stromrichter-Systemen.

Die Erkennung der Netzimpedanz in Verteilungsnetzen mit großem resistiven Anteil und hoher Integration von stromrichtergekoppelten Systemen kann zur Erkennung der Netzqualität und des Netzzustands genutzt werden. Dabei sollte das mit Hilfe von LSTM und Transformer Networks erstellte Modell direkt mit den Messabgriffen eines netzbildenden Batterie-stromrichters interagieren. Die Entwicklungsphasen von neuen Ideen bis zu ihrer Anwendung in der Praxis durchlaufen verschiedene Stufen der Entwicklung, Optimierung, Verifizierung und abschließenden Validierung.

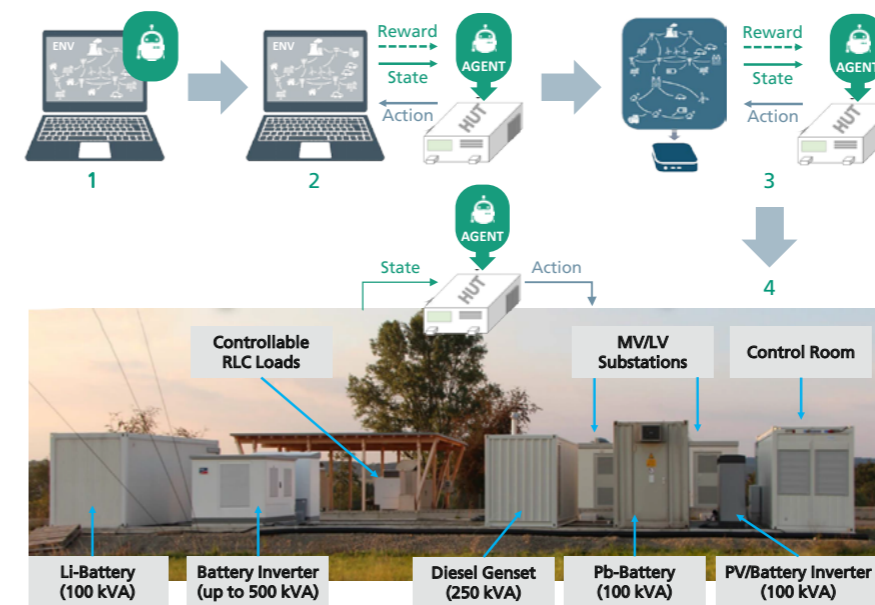


Abbildung 11: Entwicklungsphasen für schematisches Transfer Learning von Regelungs-Agenten. Beispiel: Smarte RONT Betrieb.

Ausblick

Die Leistungselektronik spielt in der Energietechnik eine zentrale Rolle: ob beim Laden und Betreiben von alltäglichen Konsumgütern bis hin zum essenziellen Transport auf der Schiene und der aufkommenden Elektromobilität (E-Fahrzeuge und Ladesysteme), der nachhaltigen Stromerzeugung (wie Solar, Wind), den Speichersystemen (wie Batterie- und Wasserstoffsysteme) und dem Energietransport (wie HGÜ-Systeme) bis hin zur intelligenten, aber auch robusten Versorgungssicherheit (wie USV) im Heimbereich sowie für das nationale und globale Netz. Die Leistungselektronik ist die Basistechnologie, auf welche die Zukunft aufgebaut ist.

Das Spotlight-Projekt **CTRL** untersuchte, wie KI-Lösungen intelligenter Regelung von Netzwerkkomponenten eingeführt, weiterentwickelt und während der Entwicklungsphasen übertragen werden können. Zu diesem Zweck wurden die verschiedenen Prozesse der Simulationen, des Rapid Control Prototyping, des Hardware-in-the-Loop und der Felddemonstration genutzt, um lernende Agenten durch Transfer Learning auf die nächste Ebene zu übertragen. Durch die schrittweise Erweiterung realistischerer Umgebungen kann die Interpretierbarkeit des Blackbox-Agenten überprüft werden, was die Akzeptanz möglicher Feldintegrationen erhöht. Abbildung 11 zeigt, wie eine vertrauenswürdige Validierung von vortrainierten Reinforcement Learning Agenten schrittweise in ein Smart Grid integriert werden kann.

1. Offline Training
 - Simplified environment
 - Identification of RL parameters
2. RCP Training
 - Simplified environment
 - HW-Agent/interfaces
3. HIL Training/Validation
 - Complex environment and more realistic environment
4. Laboratory/Field
 - Real application



Energiemanagement

»Um die Energiewende zu realisieren, arbeiten wir gemeinsam mit unseren Partnern daran, Flexibilität zugänglich, beobachtbar und zuverlässig steuerbar zu machen – KI-Verfahren bieten uns dabei enorme Potenziale«

Alexander Dreher

Produktmanager für Energiemanagement-Systeme,
Abteilung Energieinformatik und Informationssysteme

Forschung

Energiemanagement-Systeme (EMS) reichen von der Einführung von Energieeffizienz- und Prozessoptimierungsmaßnahmen im Endverbrauch von Energie in Industrie und Haushalten bis hin zur operativen Einsatzplanung im Betrieb von Energieerzeugungs- und Verbrauchseinrichtungen. Sie sind dabei ein integraler Bestandteil der Digitalisierung und Automatisierung von Energiesystemen.

Im Rahmen der Spotlights des K-ES wurden EMS insbesondere mit Blick auf die Potenziale von KI- und ML-Algorithmen für Planung und Optimierung von Energieanlagen untersucht. Klassische Ansätze in Forschung und Anwendung setzen für die Einsatzoptimierung beispielsweise auf die Dynamische Programmierung, die gemischt-ganzzahlige lineare Programmierung oder die nichtlineare Programmierung. Die Herausforderungen dieser Verfahren sind zum einen der hohe Ressourcenbedarf in Form von Rechenkapazität und Rechenzeit sowie die damit verbundenen Kosten. Andererseits werden gerade für dezentrale Anlagen im Endverbraucherbereich Systeme benötigt, die schnell und flexibel auf Veränderungen im Umfeld reagieren können.

KI- und ML-Verfahren, die von der wissenschaftlichen Gemeinschaft zur Lösung des Einsatzoptimierungsproblems untersucht werden, reichen von wissensbasierten Systemen über evolutionäre Algorithmen bis hin zu selbstlernenden Systemen des Reinforcement Learning [Richter et al., 2022]. Die letztgenannten selbstlernenden Systeme weisen ein erhebliches Potenzial auf, insbesondere seit dem Aufkommen des sogenannten Deep Reinforcement Learning (DRL), in welchem tiefe neuronale Netze mit Reinforcement Learning kombiniert werden [Mnish et al., 2016].

Angesichts der bahnbrechenden Erfolge, die mit diesen Algorithmen in Anwendungen wie Schach [Silver et al. 2018] und Go [Silver et al, 2016] erzielt wurden, ist es nicht verwunderlich, dass WissenschaftlerInnen in Bereichen wie der Energiesystemanalyse den Algorithmen zunehmend Aufmerksamkeit schenken. Einsatzgebiete im EMS-Kontext reichen dabei von der Optimierung von sog. Microgrids [Zhang et al., 2018] über industrielle Anwendungen bis hin zu Heim-Energiemanagement-Systemen [Ye et al., 2020], [Dreher et al., 2022].

Anwendung

Prinzipiell können überall dort, wo Optimierungsverfahren für das Management von Energieanlagen eingesetzt werden, auch Verfahren der KI und des ML angewandt werden. Aufgrund der sehr fortgeschrittenen klassischen Methoden gehört es zu einem nicht unerheblichen Teil zu den Aufgaben der angewandten Forschung und Entwicklung, geeignete Anwendungsbereiche zu identifizieren, in denen die Algorithmen tatsächlich einen Mehrwert schaffen können.

In Spotlights des K-ES wurden dazu Energiemanagement-Aufgaben und -Systeme analysiert. Industrielle Anwendungen wurden dabei in den Spotlights **HeatCast**, **Cognition2HydrogenForce** und aktuell **Cognition2Industry** in den Blick genommen. Im Spotlight **SmartChargingPilot** wurden Algorithmen für das Lademanagement und Heim-Energiemanagement-Systeme entwickelt.

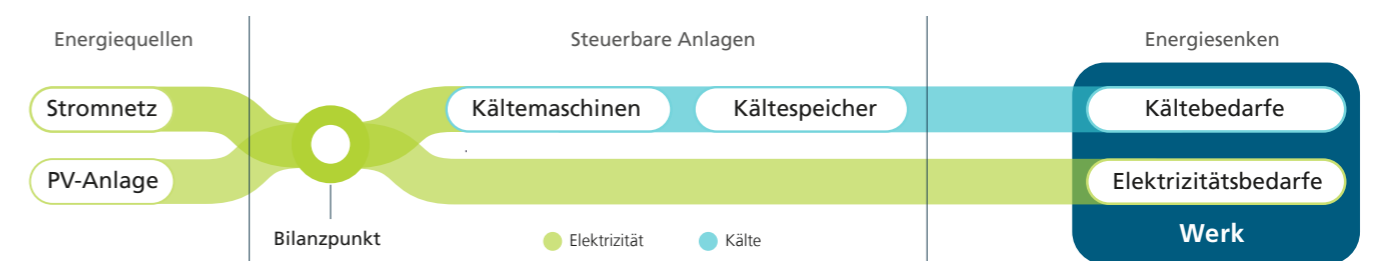


Abbildung 12: Schematische Darstellung der Energieversorgung und Flexibilisierungsmöglichkeiten des Fertigungswerkes.

Im Spotlight **HeatCast** wurde gemeinsam mit einem Technologiehersteller das Energiemanagement in einem Fertigungswerk unter die Lupe genommen. Abbildung 12 gibt einen schematischen Überblick über Energiequellen, -senken und die steuerbaren Kältemaschinen des Werks. Die Kältespeicher des Systems ermöglichen dabei die teil-flexible Verschiebung des Einsatzes der Kälteerzeugungsanlagen hin zu Zeiten, in denen PV-Strom erzeugt oder Preise des Strombezugs günstig sind. Ein Fokus lag im Projekt auf der Entwicklung der für das Energiemanagement erforderlichen Kälte- und Strombedarfsprognosen.

Im Projekt **Cognition2HydrogenForce** wurden, gemeinsam mit einer technischen Hochschule, die Potenziale von Algorithmen des DRL für den Einsatz in der erneuerbaren Wasserstoff-Elektrolyse für industrielle Gasturbinen untersucht. Die Abbildung 13 zeigt das untersuchte System, welches aus einem Windpark, einem Elektrolyseur für die Wasserstofferzeugung, einem Wasserstoffspeicher sowie einer Gasturbine zur Deckung der industriellen Wärme- und Strombedarfe besteht.

Im Projekt und der daraus entstandenen Veröffentlichung [Dreher et al., 2022 (1)] konnte im direkten Vergleich mit einem regelbasierten und einem Dynamic Programming-Modell gezeigt werden, dass die DRL-Algorithmen bereits in der Lage sind, die Ergebnisse der regelbasierten Verfahren deutlich zu übertreffen. Dies wird auch aus Abbildung 14 ersichtlich, welche die simulierte Einsatzplanung der Wasserstoffelektrolyse darstellt. Die obere Teilabbildung zeigt den Einsatz des Elektrolyseurs auf, welcher durch die volatile Windstromerzeugung ebenfalls fluktuiert.

In der Abbildung 14 (b) ist die Befüllung des Wasserstoffspeichers im Vergleich des optimalen dynamischen Programms (DP) mit dem unteren Benchmark des regelbasierten Ansatzes (RB) und dem Reinforcement-Learning basierten Ansatz (RL) dargestellt. Es ist gut zu erkennen, dass der RL-Ansatz deutlich näher an den Ergebnissen des optimalen DP-Modells liegt.

Im Spotlight **SmartChargingPilot** wurden Algorithmen für das Lade- und Heim-Energiemanagement entwickelt. Abbildung 15 zeigt die Resultate eines trainierten RL-Agenten, welcher das Lademanagement für ein Elektrofahrzeug, das Speichermanagement eines Heimspeichersystems sowie die Steuerung einer Wärmepumpe erlernt hat. Dabei lässt sich gut erkennen, dass der Algorithmus die Haushaltslasten einschließlich des Batteriespeichers so koordiniert, dass sie den durch die PV-Anlage eigenerzeugten Strom optimal aufnehmen.

Zu erkennen ist auch, wie der Batteriespeicher koordiniert entladen wird, um die Last zu bedienen, welche durch die Wärmepumpe in Stunden ohne Stromerzeugung entsteht. Nicht dargestellt ist hier, dass der Algorithmus ebenfalls in der Lage ist, hohe Preisspitzen zu vermeiden, indem erforderliche Netzbezüge in Strompreistälern bedient werden.

Im Verlauf des Projekts wurden anschließend Algorithmen für das intelligente Laden von multiplen Ladestationen an Unternehmensstandorten entwickelt. Zur Demonstration wurden zwei Ladestationen am Standort des Fraunhofer IEE installiert.

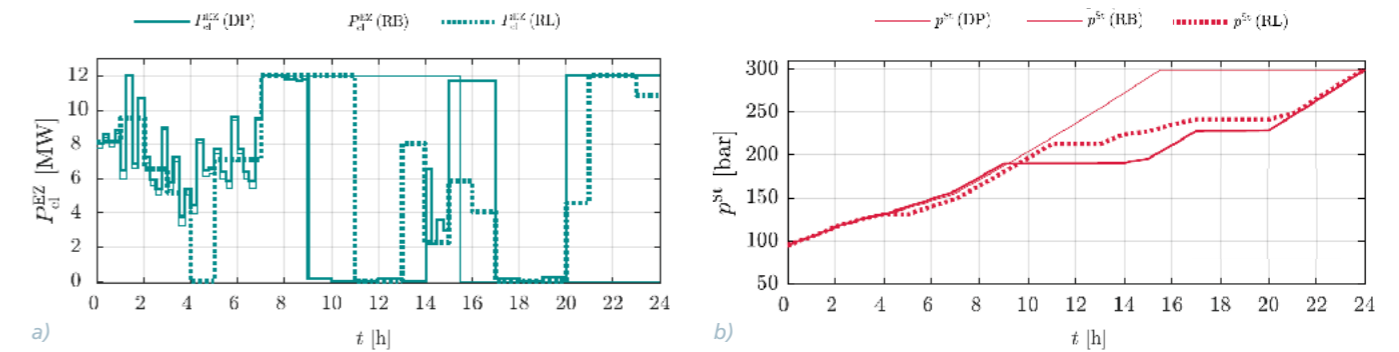


Abbildung 14: Potenziale der RL-Algorithmen im Vergleich zu DP und RB.




Abbildung 15: Ergebnisse der Anlageneinsatzplanung des Reinforcement Learning-Agenten für ein Heim-Energiemanagement-System inklusive Lademanagement.

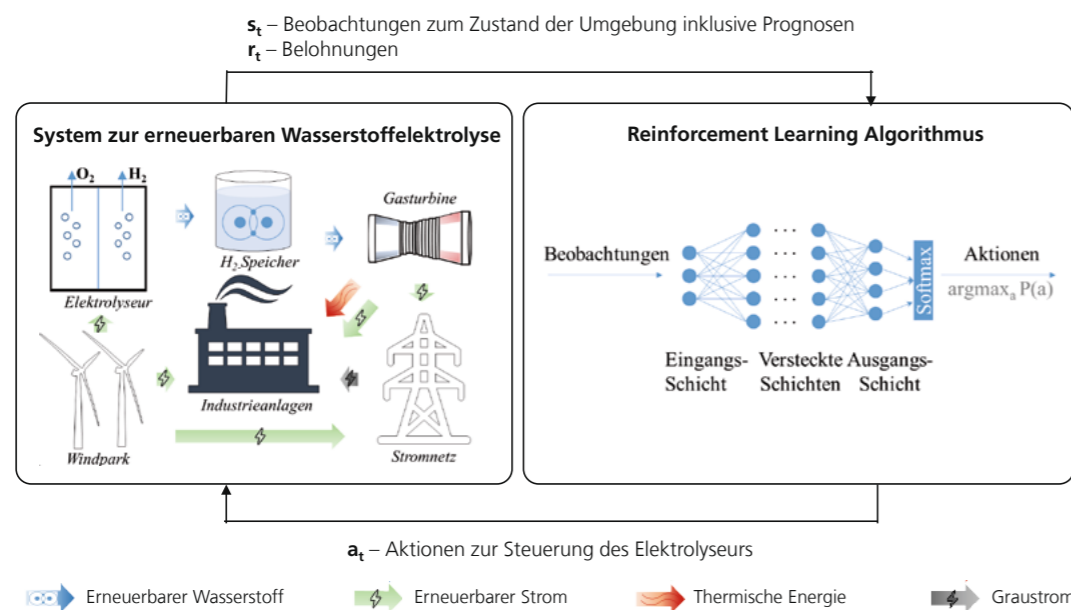


Abbildung 13: Grafische Darstellung des Systems zur erneuerbaren Wasserstoffelektrolyse sowie des Einsatzes der RL-Algorithmen [Dreher et al., 2022 (1)].

Ausblick

Energiemanagement-Systeme werden eine zentrale Rolle bei der Digitalisierung und Automatisierung zukünftiger Energiesysteme spielen. Ob bei der Einsatzplanung von Energieerzeugungs-Portfolios oder der Optimierung von verbrauchsseitigen Einrichtungen von Industrieanwendungen, über Quartiere bis hin zu Ein- und Zweifamilienhaushalten.

Die treibenden Kräfte für die Entwicklung bis hin zum flächendeckenden Einsatz von EMS sind Herausforderungen wie hohe Energiepreise und Preisvolatilitäten auf den Energiemärkten. Sie animieren Unternehmen und Endverbraucher zu kostenreduzierenden Maßnahmen beim Energiebezug und lassen Investitionen in Digitalisierungsmaßnahmen attraktiver erscheinen. Unterstützt wird diese Entwicklung insbesondere bei Unternehmen durch Aktivitäten zur Energieeinsparung und Eigenenergieerzeugung, mit dem Ziel CO₂-Emissionen zu reduzieren und mittelfristig die Klimaneutralität zu erreichen.

Wichtige Unterstützung muss von der regulatorischen Seite kommen, um Geschäftsmodelle zur Aktivierung der bisher ungenutzten Flexibilitätpotenziale zu ermöglichen und zu fördern. Im Haushaltsbereich beispielsweise werden künftige Regelungen des Energiewirtschaftsgesetzes (insbes. §14a EnWG), aber auch zur Koordinierung von Energieanlagen hinter dem Netzanschlusspunkt – Stichwort »Digitaler Netzanschlusspunkt« - eine tragende Rolle spielen.

Auf der technologischen Seite stehen Lösungen zur Verfügung, um die Flexibilisierung der Verbrauchsseite zu vollziehen. Großes Potenzial für kostengünstige, ressourcenschonende und flexible Lösungen liegen dabei im Einsatz von KI- und ML-Verfahren.

Forschung

Der Anteil der Erneuerbaren Energien (EE) an der Bruttostromproduktion hat sich in Deutschland in den letzten 10 Jahren mehr als verdoppelt und lag in 2021 bei 41,1 % [Umweltbundesamt, 2022]. Bis zum Jahr 2050 ist das Ziel 80 % der erzeugten Energie durch EE zu produzieren. Insbesondere die Erzeugung aus Wind und Photovoltaik (PV) ist dabei sehr volatil, lässt sich nur mit Unsicherheit prognostizieren und ist entsprechend schwer planbar. Durch den immer größer werdenden Anteil von EE-Erzeugern benötigen die Energieversorgungsunternehmen (EVU) innovative Lösungen, um ihren eigenen Bilanzraum effizient zu bewirtschaften. Strombörsen (z.B. EPEX SPOT, Nord Pool) bieten neben längerfristigen Terminkontrakten auch den Day-Ahead Markt, sowie den kontinuierlichen Intraday-Handel an. Auf diesen können Anbieter Strom kurzfristig vor der eigentlichen Distribution handeln und sind somit in der Lage auf Prognoseänderungen bei EE oder auf Planungsfehler zu reagieren. Momentan findet jedoch der Handel an den Strombörsen entweder durch den Menschen oder mit automatisierten regelbasierten Systemen statt, was im zukünftigen hochgradig dezentralen Energiesystem in vielerlei Hinsicht unbefriedigend ist. Mit Blick auf den Handel durch Experten ist immer noch eine große Menge an Fachwissen vonnöten, was für kleinere Unternehmen eine Eintrittsbarriere auf den Strommarkt darstellt. Gleichzeitig ist bei regelbasierten Systemen meist ein großer Teil der Komplexität des Strommarktes ausgeblendet, wodurch die Systeme häufig nicht das gesamte Potenzial voll ausschöpfen. Darüber hinaus verlieren die Systeme durch die starre Regelbasis Flexibilität, die gerade durch die steigende Anzahl an EE dringend benötigt wird.

Aus diesem Grund werden in den K-ES Spotlights zum Themenbereich Energiehandel mehrere Methoden und Lösungsansätze aus dem Bereich der Künstlichen Intelligenz (KI)

untersucht, mit dem Ziel die Entwicklung von automatisierten Handelssystemen voranzutreiben. Die Handelssysteme sollen Nutzer beim Handel unterstützen, um beispielsweise kurzfristige Prognosefehler auszugleichen und damit zur Systemstabilität beizutragen und möglichen Über- und Unterdeckungen des Energiesystems entgegenzuwirken. Methodisch wird dabei ein großer Fokus auf die Verfahren des Maschinellen Lernens (ML), insbesondere des Reinforcement Learning (RL), gesetzt, da diese in den letzten Jahren deutliche Entwicklungssprünge in anderen Disziplinen erzielten und besonders gut mit komplexen Fragestellungen umgehen können.

In den Spotlights **Deep Energy Trade**, **PDET**, **Community Trading** sowie **AI-InnovA** wurde insbesondere die Methode des Deep Reinforcement Learnings eingesetzt, da mit dieser ein automatisierter Handelsagent erstellt werden konnte. Dabei fokussierten sich auf der einen Seite die ersten drei Spotlights auf den Energiehandel aus Sicht von Windkraftbetreibern, um kurzfristig Kapazitäten zu handeln. Auf der anderen Seite wurde im Spotlight **AI-InnovA** Deep Reinforcement Learning zur Unterstützung der Entscheidungsfindung des Energiehandels im Rahmen von Innovationsausschreibungen eingesetzt.

Aus methodischer Sicht wird das Reinforcement Learning als ein Markov Prozess erster Ordnung beschrieben, wo man durch einzelne Aktionen von einem Zustand in den nächsten kommt. Wie man in Abbildung 16 erkennen kann, ist dabei die Grundidee, dass ein Agent in einer Umgebung (Environment) platziert wird, um dort selbstständig Aktionen auszuführen. Dafür werden von der Umgebung alle benötigten Informationen eines Zeitpunktes t in einem State s_t zusammengefasst und an den Agenten weitergegeben. Dieser entwickelt daraus eine mögliche Aktion a_t . Mit dieser Aktion a_t kann

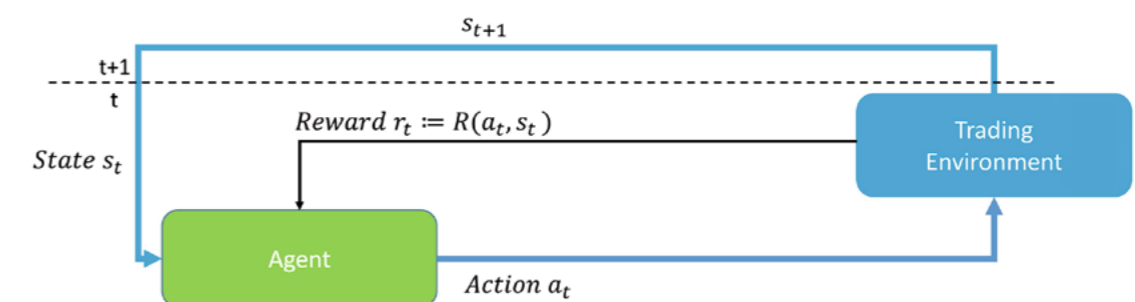


Abbildung 16: Schematische Darstellung des Reinforcement Learning Konzeptes. Die Handelsumgebung gibt dem Agenten einen State s_t , aus dem der Agent die Action a_t ableitet. Die Handelsumgebung führt diese aus und errechnet einen Reward r_t . Ziel des Agenten ist es diesen Reward zu maximieren.

Energiehandel

»Die Automatisierung des Energiehandels bietet das Potential in volatilen Energiemärkten schnelle und präzise Handelsentscheidungen zu treffen«

Malte Lehna

Abteilung Energieinformatik und Informationssysteme

AI-Innova



Community Trading



Deep Energy Trade



PDET



dann wiederum die Umgebung die Performance des Agenten einschätzen. Hierfür wird ein Reward r_t berechnet, welcher entweder als Belohnung oder als Bestrafung eingesetzt werden kann. Primärziel des Agenten ist es dabei, den Reward zu maximieren.

Die Weiterentwicklung von Reinforcement Learning zum Deep Reinforcement Learning ist nun, dass man als Agent ein Neuronales Netz verwendet (Abbildung 17).



Abbildung 17: Der Handelsagent besteht aus einem Neuronalem Netz. Erhält der Agent einen neuen Input, werden die Informationen durch das Netz zu einer Policy transformiert, aus der dann eine Aktion ausgewählt wird.

Dieses transformiert den State s_t durch die Netzschichten, um am Ende eine Entscheidung (Policy) auszuwählen. Auf Grund der Struktur der ausgewählten Algorithmen werden dabei nicht deterministische, sondern stochastische Strategien erzeugt, welche eine Erkundung der möglichen Aktionen verstärkt. Somit werden durch Abwägen und Ausprobieren des Agenten selbstständig Strategien entwickelt.

Neben dem reinen Deep Reinforcement Learning wurden in den oben genannten Spotlights auch mehrere Prognosen verwendet, um den Agenten Entscheidungshilfen zur Verfügung zu stellen. Im Fall der **Deep Energy Trade** und **PDET** Spotlights wurden zum einen Windprognosen verwendet, welche aus Encoder-Decoder Recurrenten Neuronalen Netzen (RNN) bestanden [Sutskever et al., 2014]. Gleichzeitig wurden auch Preisprognosen bereitgestellt, welche kurzfristige Preissprünge erkennen konnten, genauer beschrieben in [Scholz et al., 2021]. Für das Projekt **AI-InnovA** wurden hingegen Ensemble Prognosen der Windenergieeinspeisung verwendet. Dies ist insbesondere interessant, da die Ensemble Prognosen im Vergleich zu deterministischen Prognosen einen möglichen Vorteil für Reinforcement Learning bieten.

Anwendung

Im Spotlight **Deep Energy Trade** wurde ein erster Prototyp in Form eines Demonstrators entwickelt, welcher auf einem kleinen Datensatz positive Handelsergebnisse erzeugt und das Szenario noch erweitert [Lehna et al., 2022]. Anschließend wurde im Spotlight **Community Trade** das Zusammenspiel mehrerer dieser Agenten genauer untersucht. Hierbei ist insbesondere das Portfoliomanagement mit mehreren Handelsagenten von Interesse.

Zu Beginn der Entwicklung des automatisierten Handelsagenten musste sichergestellt werden, dass die Anforderungen auch einer realistischen Betrachtungsweise des Marktes entsprechen. Aus diesem Grund wurden für die Spotlights Deep Energy Trade und PDET als Szenario der Verkauf von Leistung aus Sicht eines Windparkbetreibers gewählt. Gleichzeitig sollten sowohl das Training als auch die Tests auf Basis der Intraday Daten des deutschen Strommarktes erfolgen. Somit konnten wir sicherstellen, dass Erkenntnisse auch in der Praxis umsetzbar sein werden.

Bei genauerer Betrachtung der Umsetzung mit Deep Reinforcement Learning musste eine Handelsumgebung auf Basis von

Transaktionsdaten des deutschen Intraday Marktes entwickelt werden. Diese stellte dem Agenten sowohl die Energiemarktdaten (Energiepreise und deren Einflussfaktoren) als auch die Windprognosen bereit. Erhielt die Handelsumgebung die Aktionen des Agenten, so wurden diese verrechnet und ein Reward in Höhe der Kauf-/Verkaufspreise ausgezahlt. Im Gegensatz zu früheren Arbeiten anderer Wissenschaftlerinnen und Wissenschaftler steigerten wir die Komplexität deutlich, um eine reellere Betrachtung zu gewährleisten. So wurden zum Beispiel anstelle von 24 Zeitschritten pro Tag [Bertrand et al., 2019] die stündlichen Handelsprodukte in minütlicher Auflösung betrachtet. Folglich musste der Handelsagent viele kurzfristigere Handelsentscheidungen fällen, wodurch nicht mehr nur ein langfristiger Trend betrachtet wurde, sondern auch kurzfristige Schwankungen antizipiert und ausgenutzt werden konnten. Gleichzeitig fügten wir durch das Setting des Windparkbetreibers eine weitere Schwierigkeit hinzu, da der Agent sein Handelsvolumen und damit seine Strategie regelmäßig an die aktuellen Windprognosen (Aktualisierung alle 15 Minuten) anpassen musste. Diese Schwierigkeit wurde entsprechend berücksichtigt, in dem der Reward r_t in zwei unterschiedliche Teil-Rewards aufgeteilt wurde.




Abbildung 18: Beispielhafte Handelsbewegungen des Deep Reinforcement Learning Agenten. Der Agent (rot) folgt dabei der Preisbewegung (blau) eines Intraday Produktes. In grau ist die beste Baseline dargestellt, welche auf Basis der Preisprognosen agierte. Der Agent hat die Baseline mit einer Verbesserung von über 45% geschlagen.

So wurde zum einen ein Trade Reward ermittelt und gleichzeitig ein Volume Reward entwickelt, um die Änderung der Windprognose zu berücksichtigen. Nachdem sowohl die Entwicklung der Umgebung und des Agenten abgeschlossen waren, wurden das Modell mit Hilfe des Proximal Policy Optimization (PPO) Algorithmus [Schulman et al., 2017] trainiert, wobei die Hyperparameter durch das Population Based Training [Jaderberg et al., 2017] optimiert wurden.

Durch die Konzeption der Umgebung als auch das Verwenden von State-of-the-Art Algorithmen konnten erfolgreich Agenten erstellt werden. Auf den Testdaten erzielten diese bis zu 45 % bessere Werte als regelbasierte Baseline Agenten. Ein beispielhafter Lauf des Handelsagenten kann man in der Abbildung 18 sehen, wo dieser dem Preisabstieg folgt. Ein Grund für den Erfolg der Agenten ist, dass diese auch auf kurzfristige Preissprünge reagieren konnten, wie man in der Abbildung 18 bei

22:10 Uhr sehen kann. Der Intraday Preis fiel in diesem Zeitraum kurzfristig ab und der Agent reagierte entsprechend. Diese kurzfristige Reaktion konnten die regelbasierten Systeme nicht leisten.

Mit Blick auf den Spotlight **Community Trading** ergab sich im Anschluss von PDET die Frage, wie man aus mehreren unterschiedlichen Agenten ein gemeinsames Portfolio erzeugen kann. Dabei ist das Ziel, durch die flexible Kombination der einzelnen Akteure das Handelsrisiko des Gesamtportfolios zu reduzieren. Auch wenn die Entwicklungen noch nicht vollständig abgeschlossen sind, zeigt sich bereits, dass eine Aggregation durch beispielsweise zeitreihenbasierte Methoden klar einen Mehrwert bringen und einzelne Ausreißer der Akteure reduziert werden können. Somit können durch ein smartes Portfolio das Handelsrisiko sowie die Volatilität gesenkt werden.

Ausblick

In den letzten Jahren ist der Anteil der kurzfristig gehandelten Energie kontinuierlich angestiegen [EPEX, 2022], wodurch die Intraday Märkte eine immer größere Bedeutung bekommen. Gleichzeitig erhöht sich jedoch die Komplexität durch den Zubau der erneuerbaren Energien und die starke Abhängigkeit zu den Energiepreisen weiter.

Durch ein regelmäßiges Retraining können unterschiedliche Agenten für die einzelnen Volatilitätslevel erstellt werden, um mit der Unsicherheit besser umzugehen. Gleichzeitig müssen jedoch für den Praxiseinsatz der Handelsagenten weitere Untersuchungen durchgeführt werden, um sicherzustellen, dass die Agenten robuste und sichere Entscheidungen treffen.













Um dies zu gewährleisten, muss zum einen die Handelsumgebung deutlich auf die gestiegene Komplexität angepasst werden. Zum anderen empfiehlt es sich, das Verhalten von mehreren Agenten untereinander zu untersuchen, um mögliche Verstärkungseffekte frühzeitig zu erkennen.

Ein erster Schritt in diese Richtung ist dabei die Entwicklung einer Orderbook Umgebung, auf welcher die Agenten selbstständig mehrere Tradinggebote, sowohl für die BUY- als auch die SELL-Seite, stellen können. Die Entwicklung der Umgebung wurde bereits in dem Projekt **KES-Gym** ausgearbeitet, sodass nun die ersten Tests mit Deep Reinforcement Learning den nächsten Entwicklungsschritt darstellen.

Spotlights | Übersicht



Die Spotlights sind ambitionierte Forschungsprojekte, die gangbare Wege der Künstlichen Intelligenz in der Energiewirtschaft und Energiesystemtechnik erkunden

							
AAE	AI-InnovA	Aldentify	Alsland	ARCANA	Cognition ² H ₂ Force	CTRL	Data4Grid-Challenge
							
Deep Energy Trade	DeepBirdDetect	DisLF	EV Forecast	GANs4RE	GNN4PG	GRADS	GRAF-KoWi
							
HeatCast	InvEx	KESL2RPN	KI OPF	Netzlupe	NeuRaSat	PDET	PowerGraph
							
Probabilistische Netzzustandsprognosen	ROSALIE	SmartChargingPilot	SmartTE	Temporal Fusion Transformers	TLP4Heat	VemoSat	Vertikale Lastprognose

Literaturverzeichnis

Executive Summary

[EU Commission] <https://ec.europa.eu/info/funding-tenders/opportunities/portal/screen/opportunities/topic-details/horizon-cl5-2024-d3-01-11>

Kognitive Energiesysteme

[Bremm, 2020] Bremm, S., Linh Le, B., Riechers, L., Mix, L., und Bendjebbour, Y. »Künstliche Intelligenz für die Energiewirtschaft.« BDEW Bundesverband der Energie und Wasserwirtschaft. 2020. https://www.bdew.de/media/documents/BDEW_KI_LAUNCH_2406_1ADiAzP.pdf

Netzbetrieb

[ACER, 2019] Agency for the Cooperation of Energy Regulators. »Methodology for coordinating operational security analysis. ACER Decision on CSAM: Annex I« (2019) https://eepublicdownloads.entsoe.eu/clean-documents/nc-tasks/EBGL/SOGL_A75.1_190621__ACER%20Decision%20on%20CSAM_Annex%20I.pdf

[Wang et al., 2022] Zhenqi Wang, Jan-Hendrik Menke, Florian Schäfer, Martin Braun, Alexander Scheidler, Approximating multi-purpose AC Optimal Power Flow with reinforcement trained Artificial Neural Network, Energy and AI, Volume 7, 2022, 100133, ISSN 2666-5468, <https://doi.org/10.1016/j.egyai.2021.100133>.

[Wang et al., 2022 (1)] Wang, Z., Wende-von Berg, S., Braun, M., »Robust N-1 secure HV grid flexibility estimation for TSO-DSO coordinated congestion management with deep reinforcement learning.« NEIS 2022; Conference on Sustainable Energy Supply and Energy Storage Systems, Hamburg, Germany, 2022, pp. 1-7.

Prognosen

[Brauns et al., 2022] Brauns, K., Scholz, C., Schultz, A., Baier, A., Jost, D. »Vertical power flow forecast with LSTMs using regular training update strategies.« Energy and AI, Volume 8, 2022: 100143,ISSN 2666-5468, <https://doi.org/10.1016/j.egyai.2022.100143>.

[Lim et al., 2021] Lim, B. et al. »Temporal fusion transformers for interpretable multi-horizon time series forecasting.« International Journal of Forecasting (2021)

Resilienz

- [Bundesnetzagentur, 2021] »Künstliche Intelligenz in den Netzsektoren – Zusammenfassung des Berichts über den Marktdialog der Bundesnetzagentur.« Bundesnetzagentur (2021)
- [Commission, E., 2021] »Proposal for a Regulation of the European Parliament and the Council: Laying Down Harmonised Rules on Artificial Intelligence (Artificial Intelligence Act) and Amending Certain Union Legislative Acts.« 2021. <http://digital-strategy.ec.europa.eu/en/library/proposal-regulation-laying-down-harmonised-rules-artificial-intelligence-artificial-intelligence>
- [Häring, 2021] Häring, I. »Technical Safety and Reliability Methods for Resilience Engineering.« Springer, 2021
- [Kim, 2018] Kim, B. »Interpretability Beyond Feature Attribution: Quantitative Testing with Concept Activation Vectors (TCAV).« (2018)
- [Roelofs et al., 2021] Roelofs, C., Lutz, M.-A., Faulstich, S., Vogt, S. »Autoencoder-based Anomaly Root Cause Analysis for Wind Turbines.« Energy and AI, March 2021

Leistungselektronik

- [Zhao et al., 2021] Zhao, S., Blaabjerg, F. und Wang, H. »An Overview of Artificial Intelligence Applications for Power Electronics.« IEEE Trans. Power Electronics, 2021

Energiemanagement

- [Dreher et al., 2022] Dreher, A., Martmann, L. M., Lehna, M., Roelofs, C., Bergstraser, J., Scholz, C., Slaby, W., & Wetzler, H. (2022). »AI agents assessing flexibility: the value of demand side management in times of high energy prices.« In: 2022 18th International Conference on the European Energy Market (EEM) (pp. 1-9). IEEE. doi: 10.1109/EEM54602.2022.9920982
- [Dreher et al., 2022 (1)] Dreher, A., Bexten, T., Sieker, T., Lehna, M., Schütt, J., Scholz, C., & Wirsum, M. (2022). »AI agents envisioning the future: Forecast-based operation of renewable energy storage systems using hydrogen with Deep Reinforcement Learning.« Energy Conversion and Management, 258, 115401. doi: 10.1016/j.enconman.2022.115401
- [Mnish et al., 2016] Mnish, V., Badia, A. P., Mirza, M., Graves, A., Lillicrap, T., Harley, T., Silver, D., Kavukcuoglu, K., (2016). »Asynchronous methods for deep reinforcement learning.« In: International conference on machine learning, pages 1928–1937. PMLR.
- [Richter et al., 2022] Richter, L., Lehna, M., Marchand, S., Scholz, C., Dreher, A., Klaiiber, S., & Lenk, S. (2022, July). »Artificial Intelligence for Electricity Supply Chain automation.« Renewable and Sustainable Energy Reviews.
- [Silver et al., 2016] Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., & Hassabis, D. (2016). »Mastering the game of Go with deep neural networks and tree search.« Nature.

- [Silver et al., 2018] Silver, D., Hubert, T., Schrittwieser, J., Antonoglou, I., Lai, M., Guez, A., Lanctot, M., Sifre, L., Kumanran, D., Graepel, T., Lillicrap, T., Simonyan, K., & Hassabis, D. (2018). »A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play.« Science.
- [Ye et al., 2020] Ye, Y., Qiu, D., Wu, X., Strbac, G., & Ward, J. (2020). »Model-Free Real-Time Autonomous Control for a Residential Multi-Energy System Using Deep Reinforcement Learning.« IEEE Transactions on Smart Grid, 11(4), 3068-3082. doi: 10.1109/TSG.2020.2976771
- [Zhang et al., 2018] Zhang, D., Han, X., Deng, C. (2018). »Review on the research and practice of deep learning and reinforcement learning in smart grids.« CSEE Journal of Power and Energy Systems, 4(3), 362-370. doi: 10.17775/CSEEJPES.2018.00520

Energiehandel

- [Bertrand et al., 2019] Bertrand, G., Papavasiliou, A. »Reinforcement-learning based threshold policies for continuous intraday electricity market trading.« 2019 IEEE Power & Energy Society General Meeting (PESGM). IEEE, 2019
- [EPEX, 2022] »Dynamic year for European power markets.« <https://www.epexspot.com/en/news/dynamic-year-european-power-markets>
- [Jaderberg et al., 2017] Jaderberg, M. et al. »Population based training of neural networks.« arXiv preprint arXiv:1711.09846 (2017)
- [Lehna et al., 2022] Lehna, M. et al. »A Reinforcement Learning approach for the continuous electricity market of Germany: Trading from the perspective of a wind park operator.« Energy and AI 8 (2022): 100139
- [Scholz et al., 2021] Scholz, C. et al. »Towards the prediction of electricity prices at the intraday market using shallow and deep-learning methods.« Workshop on mining data for financial applications. Springer, Cham, 2021
- [Sutskever et al., 2014] Sutskever I., Vinyals O., Le QV. »Sequence to sequence learning with neural networks.« In: Advances in neural information processing systems. 2014, p. 3104–12
- [Schulman et al., 2017] Schulman, J. et al. »Proximal policy optimization algorithms.« arXiv preprint arXiv:1707.06347 (2017)
- [Umweltbundesamt, 2022] <https://www.umweltbundesamt.de/themen/klima-energie/erneuerbare-energien/erneuerbare-energien-in-zahlen#statusquo>

Begleitkreismitglieder

Wirtschaft

E.ON SE

Dr.-Ing. Patrick Hochloff

TenneT TSO GmbH

Axel Kiessling

Wissenschaft

Gesellschaft für wissenschaftliche Datenverarbeitung mbH Göttingen

Prof. Dr. Ramin Yahyapour

Julius-Maximilians-Universität Würzburg

Prof. Dr. Andreas Hotho

RWTH Aachen

Prof. Dr.-Ing. Antonello Monti

Universität Kassel

Prof. Dr. rer. nat. Bernhard Sick

Förderer

Hessisches Ministerium für Wissenschaft und Kunst

Dr. Ulrike Mattig

Förderer

HESSEN



**Hessisches Ministerium
für Wissenschaft
und Kunst**

Das Hessische Ministerium für Wissenschaft und Kunst hat das Aufbauprojekt »Kognitive Energiesysteme« mit Mitteln des Landes Hessen von 2019 bis 2023 gefördert. Damit ist es gelungen, für das auf Energiewirtschaft und Energiesystemtechnik spezialisierte Fraunhofer IEE in Kassel einen weiteren wichtigen Forschungsschwerpunkt für die erfolgreiche Umsetzung der Energiewende in Hessen und Deutschland zu erschließen.

Auf dieser Basis forscht und entwickelt das Fraunhofer IEE im Zukunftsfeld der künstlichen Intelligenz für ein flexibles, robustes und resilientes Energiesystem. Es stellt seine Erkenntnisse im Bereich kognitive Energiewirtschaft, kognitive Energienetze und kognitive Energiesystemtechnik für weitere Forschungsaktivitäten und Anwendungen in der Wirtschaft zur Verfügung. Der Entwicklungsprozess ist für weitere Jahre angelegt und wird mit Partnerinstituten im Rahmen eines vom BMBF geförderten KI-Servicezentrums für sensible und kritische Infrastrukturen (KISSKI) fortgeführt.

Ansprechpartner Fraunhofer IEE

Projektleitung Kognitive Energiesysteme

André Baier
andre.baier@iee.fraunhofer.de

Dr. Christoph Scholz
christoph.scholz@iee.fraunhofer.de

Netzbetrieb

Dr. Alexander Scheidler
alexander.scheidler@iee.fraunhofer.de

Prognosen

Daniel Horst (Fernerkundung)
daniel.horst@iee.fraunhofer.de

Dr. Malte Siefert (Prognosen)
malte.siefert@iee.fraunhofer.de

Resilienz

Florian Rehwald
florian.rehwald@iee.fraunhofer.de

Leistungselektronik

Dr. Ron Brandl
ron.brandl@iee.fraunhofer.de

Energiemanagement

Alexander Dreher
alexander.dreher@iee.fraunhofer.de

Energiehandel

Malte Lehna
malte.lehna@iee.fraunhofer.de

Impressum

Herausgeber

**Fraunhofer-Institut für Energiewirtschaft und
Energiesystemtechnik IEE**

Institutsleitung
Dr.-Ing. Reinhard Mackensen (komm.)
Dr.-Ing. Philipp Strauß (stellv.)

Fraunhofer IEE
Joseph-Beuys-Str. 8
34117 Kassel

info@iee.fraunhofer.de

www.iee.fraunhofer.de

Redaktion

André Baier
Dr. Gudrun Franke-Braun

Grafik und Layout

Maryna Miliushchanka

Bildnachweis

Adobe Stock | Titelseite, 4-5, 8, 10, 12, 16, 20, 24, 28, 32, 37
kunst.hessen.de | 6-7



Weitere Informationen
finden Sie unter:
www.kognitive-energie-systeme.de



Das Kompetenzzentrum Kognitive Energiesysteme (K-ES) beschäftigt sich seit Mitte 2020 mit kognitiven Prozessen für die Energiesystemtechnik, die Energiewirtschaft sowie die Energienetze. In den nächsten zehn Jahren soll sich daraus gemeinsam mit dem Fraunhofer-Institut für Energiewirtschaft und Energietechnik IEE ein internationaler Schwerpunkt für künstliche Intelligenz in Forschung und Lehre entwickeln.

Sprechen Sie uns an:

Dipl.-Math. André Baier, M.Sc.
Telefon: +49 561 7294-372
andre.baier@iee.fraunhofer.de

Fraunhofer-Institut für Energiewirtschaft
und Energiesystemtechnik IEE
Joseph-Beuys-Str. 8
34117 Kassel
www.iee.fraunhofer.de



Weitere Informationen finden Sie unter:
www.kognitive-energie-systeme.de